

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# **DIPLOMSKI RAD**

**Ana Jelić**

Zagreb, 2015.

Sveučilište u Zagrebu  
FAKULTET STROJARSTVA I BRODOGRADNJE

# DIPLOMSKI RAD

Analiza primjene algoritama problema trgovačkog putnika kod komisioniranja  
unutar visokoregalnog skladišta s vrlo uskim prolazima

**Mentor:**

Dr.sc. Goran Đukić

**Student:**

Ana Jelić

Zagreb, 2015.

## **IZJAVA**

Izjavljujem da sam ovaj rad izradila samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Ana Jelić

## **ZAHVALA**

Zahvaljujem roditeljima, sestrama i kolegama na velikoj pomoći, povjerenju i strpljenju koje su ukazali tijekom studija kao i prilikom pisanja diplomskog rada.

Također, zahvaljujem se prijatelju i programeru Robertu Gluhakoviću na iskazanoj pomoći i strpljenju.

Posebno se zahvaljujem mentoru prof. dr. sc. Goranu Đukiću koji mi je svojim prijedlozima, savjetima i sugestijama omogućio da uspješno završim ovaj rad.

Ana Jelić



SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomске ispite  
Povjerenstvo za diplomске ispite studija strojarstva za smjerove:  
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo  
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

## DIPLOMSKI ZADATAK

Student: **Ana Jelić** Mat. br.: 0035177644

Naslov rada na hrvatskom jeziku: **Analiza primjene algoritama problema trgovačkog putnika kod komisioniranja unutar visokoregalnog skladišta s vrlo uskim prolazima**

Naslov rada na engleskom jeziku: **Analysis of application of TSP algorithms for order-picking in VNA warehouse**

Opis zadatka:

Jedna od mogućih izvedbi paletnih skladišta jest i primjena visokoregalnih viličara unutar regalnog dijela s vrlo uskim prolazima, poznata pod nazivom VNA (eng. Very Narrow Aisle). Danas postoje razne izvedbe VNA viličara, a jednu od njih karakterizira i mogućnost komisioniranja robe unutar prolaza sa svih razina, pa i do desetak metara visine. Time ovakve izvedbe imaju sličnost sa izvedbom automatiziranog skladišnog sustava za komisioniranje (eng. person-on-board AS/RS), a optimizacija kretanja u procesu komisioniranja unutar regala promatra se kao specijalni slučaj problema trgovačkog putnika. To navodi na razmatranje mogućnosti primjene algoritama tog problema na kreiranje ruta (redosljedja posjećivanja lokacija) unutar regalnih prolaza i u VNA skladištima.

U radu je potrebno:

- Dati uvodni pregled skladištenja i skladišnih sustava.
- Prikazati izvedbe visokoregalnih paletnih sustava s vrlo uskim prolazima (VNA skladišta), te pregled izvedbi VNA viličara. Detaljnije prikazati izvedbe visokoregalnih viličara komisionera (eng. turret-up VNA trucks).
- Prikazati izvedbe automatiziranih skladišnih sustava. Detaljnije prikazati izvedbu sustava za komisioniranje, te objasniti metode određivanja rute komisioniranja.
- Dati prikaz problema trgovačkog putnika i pregled osnovnih heurističkih algoritama generiranja ruta.
- Za odabrane parametre dimenzija regala, veličine narudžbe (broja lokacija u ciklusu komisioniranja), brzine vožnje i dizanja viličara i dr. provesti analizu primjenjivosti heurističkih algoritama TSP problema za generiranje redosljedja prikupljanja robe u procesu komisioniranja visokoregalnim viličarem komisionerom, a s ciljem minimizacije vremena vožnje.

Zadatak zadao:

7. svibnja 2015.

Rok predaje rada:

9. srpnja 2015.

Predviđeni datum obrane:

15., 16. i 17. srpnja 2015.

Zadatak zadao:

Predsjednik Povjerenstva:

Izv. prof. dr. sc. Goran Đukić

Prof. dr. sc. Franjo Čajner

# Sadržaj

Popis slika	I
Popis tablica	III
Sažetak	IV
1. Uvod.....	1
2. Osnove skladišnih sustava.....	3
2.1. Osnove klasičnih skladišnih sustava.....	3
2.2. Analiza postojanja skladišta .....	3
2.3. Skladišne zone .....	4
2.4. Osnove automatiziranih skladišnih sustava .....	5
3. Pregled osnovnih regala u klasičnim skladišnim sustavima .....	7
3.1. Podna skladišta .....	7
3.2. Skladišta sa paletnim i poličnim regalima .....	8
3.3. Skladišta s konzolnim regalima .....	9
3.4. Skladišta s prolaznim regalima.....	10
3.5. Skladišta s protočnim regalima.....	11
3.6. Skladišta s pokretnim regalima.....	12
3.6.1. Prijevozni regali .....	12
3.6.2. Optočni (okretni) regali .....	13
4. Visokoregalna skladišta.....	15
4.1. Odluka o širini prolaza .....	15
4.2. Tipovi prolaza s obzirom na njegovu širinu .....	16
4.3. Uštede prostora u skladištima sa uskim i vrlo uskim prolazima .....	18
4.4. Produktivnost, fleksibilnost, sigurnost i troškovi .....	19
4.5. VNA transportna sredstva .....	20

4.5.1.	Viličari sa zakretnim vilicama.....	21
4.5.2.	Viličari sa zakretnom prednjom osovinom .....	22
4.5.3.	Viličari sa zakretnim jarbolom.....	23
5.	Automatizirani skladišni sustavi .....	24
5.1.	Horizontalni karuseli .....	25
5.2.	Vertikalni karuseli .....	26
5.3.	Vertikalni podizni moduli.....	28
5.4.	Crane –in-aisle AS/RS.....	29
5.4.1.	Unit-load AS/RS .....	29
5.4.2.	Mini-load AS/RS.....	30
5.4.3.	Micro-load AS/RS.....	31
5.4.4.	Person-on-bord AS/RS .....	31
5.4.4.1.	Optimalan redoslijed izuzimanja .....	33
5.4.4.2.	Band heuristika .....	34
6.	Problem usmjeravanja vozila .....	37
6.1.	Problem trgovačkog putnika.....	38
6.1.1.	Egzaktne metode rješenja problema trgovačkog putnika.....	39
6.1.2.	Heuristički algoritmi problema trgovačkog putnika .....	40
6.1.2.1.	Algoritam najbližeg susjeda .....	40
6.1.2.2.	Pohlepna heuristika .....	41
6.1.2.3.	Algoritam umetanja najbližeg .....	42
6.1.2.4.	Algoritam umetanja najudaljenijeg .....	43
6.1.2.5.	Algoritam umetanja najjeftinijeg.....	44
6.1.2.6.	Clarke i Wright algoritam ušteda .....	45
6.1.2.7.	Algoritam Christofidesa .....	45
7.	Analiza primjene komisioniranja unutar visokoregalnog skladišta s vrlo uskim prolazima .....	46
7.1.	Izračun vremena kod simultanog kretanja.....	50
7.2.	Izračun vremena kod rektilinearne kretanja .....	59

8.	Komentar rezultata analize .....	67
8.1.	Usporedba simultanog i rektilinearnog kretanja.....	67
8.2.	Usporedba s procijenjenim optimalnim rutiranjem .....	73
9.	Zaključak .....	77
10.	Literatura .....	79



## Popis slika

Slika 1. Skladišne zone.....	4
Slika 2. Podno skladište .....	7
Slika 3. Paletni regal.....	8
Slika 4. Konzolni regal.....	9
Slika 5. Drive-in regal .....	10
Slika 6. Drive-trough regal .....	11
Slika 7. Protočni regal .....	12
Slika 8. Prijevozni regal .....	13
Slika 9. Okretni regal .....	14
Slika 10. Prikaz širokog prolaza.....	16
Slika 11. Prikaz uskog prolaza .....	17
Slika 12. Prikaz vrlo uskog prolaza.....	17
Slika 13. Žični sustav vođenja.....	21
Slika 14. Viličar sa zakretnom vilicom .....	22
Slika 15. Viličar sa zakretnom prednjom osovinom .....	22
Slika 16. Viličar sa zakretnim jarbolom.....	23
Slika 17. Horizontalni karusel .....	25
Slika 18. Vertikalni karuseli.....	27
Slika 19. Vertikalni podizni modul .....	28
Slika 20. Unit-load skladišni sustav .....	30
Slika 21. Mini-load skladište.....	30
Slika 22. Person-on-board komisioniranje .....	32
Slika 23. Band heuristika .....	34
Slika 24. Algoritam najbližeg susjeda.....	40
Slika 25. Rješenje algoritma najbližeg susjeda .....	41
Slika 26. Pohlepna heuristika .....	42
Slika 27. Algoritam umetanja najbližeg .....	43
Slika 28. Algoritam umetanja najudaljenijeg.....	44
Slika 29. Nacrt viličara Jungheinrich EKX 513 .....	47
Slika 30. Jungheinrich EKX 513 .....	49
Slika 31. Prikaz slučajno odabranih lokacija.....	51

Slika 32. Prikaz kretanja kod klasičnog komisioniranja .....	52
Slika 33. Prikaz kretanja primjenom band heuristike.....	54
Slika 34. Prikaz kretanja primjenom heuristike problema trgovačkog putnika .....	56
Slika 35. Prikaz kretanja primjenom heuristike problema trgovačkog putnika i band heuristike .....	57
Slika 36. Prikaz uvjeta iz programa .....	58
Slika 37. Prikaz rezultata dobivenih programom .....	59
Slika 38. Prikaz kretanja primjenom klasičnog komisioniranja kod rektilinearne kretanja ..	60
Slika 39. Prikaz kretanja primjenom band heuristike kod rektilinearne kretanja .....	62
Slika 40. Prikaz kretanja primjenom algoritma najbližeg susjeda kod rektilinearne kretanja	63
Slika 41. Prikaz kretanja primjenom algoritma najbližeg susjeda i band heuristike kod rektilinearne kretanja.....	65
Slika 42. Prikaz rezultata dobivenih programom .....	66
Slika 43. Rezultati programa za 10 000 uzoraka.....	70
Slika 44. Prosječno vrijeme trajanja vožnje za 50 narudžbi.....	71
Slika 45. Prosječno vrijeme trajanja vožnje za 25 narudžbi.....	71
Slika 46. Prosječno vrijeme trajanja vožnje za 10 narudžbi.....	72
Slika 47. Postotak razlike vremena kretanja u korist simultane kretanja.....	73

## Popis tablica

Tablica 1. Optimalan broj traka (za zadani n) [16]: .....	35
Tablica 2. Karakteristike viličara Jungheinrich EKX 513 .....	48
Tablica 3. Slučajno odabrane točke.....	50
Tablica 4. Raspored lokacija kod klasičnog komisioniranja.....	51
Tablica 5. Izračun vremena kod primjene klasičnog komisioniranja.....	53
Tablica 6. Raspored lokacija kod primjene band heuristike .....	54
Tablica 7. Izračun vremena primjenom band heuristike .....	55
Tablica 8. Raspored lokacija kod primjene heuristike problema trgovačkog putnika .....	55
Tablica 9. Izračun vremena primjenom algoritma najbližeg susjeda .....	56
Tablica 10. Raspored lokacija kod primjene heuristike problema trgovačkog putnika i band heuristike .....	57
Tablica 11. Izračun vremena primjenom algoritma najbližeg susjeda i band heuristike .....	58
Tablica 12. Raspored koordinata.....	59
Tablica 13. Izračun vremena primjenom klasično komisioniranja .....	61
Tablica 14. Raspored koordinata.....	61
Tablica 15. Izračun vremena primjenom band heuristike .....	62
Tablica 16. Raspored koordinata.....	63
Tablica 17. Izračun vremena primjenom heuristike problema trgovačkog putnika.....	64
Tablica 18. Raspored koordinata.....	64
Tablica 19. Izračun vremena primjenom heuristike problema trgovačkog putnika i band heuristike .....	66
Tablica 20. Usporedba rezultata na 10 000 uzoraka kod simultanog i rektilinearne kretanja.....	67
Tablica 21. Razlike prosječnog trajanja vožnje u korist simultanog kretanja.....	72

## Sažetak

U ovom radu obrađena je tema analize primjene algoritma problema trgovačkog putnika kod komisioniranja unutar visokoregalnog skladišta s vrlo uskim prolazima. U prvom dijelu rada dan je uvid u klasična i automatizirana skladišta s detaljnim opisom visokoregalnih skladišta s vrlo uskim prolazom i Person-on-board sustava. U drugom, praktičnom dijelu, opisana je primjena 4 metode komisioniranja. Prva metoda je primjena klasičnog komisioniranja po  $x$  osi, druga je primjena band heuristike, treća primjena heuristike problema trgovačkog putnika preko algoritma najbližeg susjeda i četvrta kombinacija druge i treće metode tj. band heuristike i algoritma najbližeg susjeda. Sva 4 slučaja koristila su se u slučaju simultanog i rektilinearnog kretanja. Ispitivanje je provedeno na 10 000 testova koji su provedeni u programu 'Eclipse' napisanom u Java programskom jeziku.

Na kraju je dana usporedba rezultata dobivenih programom kod simultanog i rektilinearnog kretanja.

Ključne riječi: problem trgovačkog putnika, algoritam najbližeg susjeda, simultano kretanje, rektilinearno kretanje, komisioniranje, visokoregalna skladišta.

## 1. Uvod

Svako uspješno poduzeće iza sebe ima razvijene logističke procese. Logistika je proces planiranja, implementacije i kontrole efikasnog i efektivnog tijeka i skladištenja materijala (sirovina, poluproizvoda i gotovih proizvoda), usluga i povezanih informacija od točke izvora do točke potrošnje u svrhu zadovoljenja zahtjeva korisnika.

Značaj logistike i skladištenja te projektiranja skladišta u današnjim uvjetima poslovanja bilježi sve veći porast. Postoje brojna istraživanja koja su nastala na temu logistike i ispravnog skladištenja. U posljednjih 30-ak godina logistika postaje važan čimbenik u gospodarstvu svake države i primjenom logističkih načela i metoda mogu se smanjiti troškovi, što u konačnici dovodi do povećanja profita što je i cilj svakog poduzeća.

Skladište je najskuplji logistički proces, ali i pruža mogućnost za najveći napredak. Budući da još uvijek nije moguće izbaciti postupak skladištenja iz proizvodnje, bitno je da skladišni sustav funkcionira kao jedna skladna cjelina kako bi se smanjili zastoji, ubrzalo vrijeme isporuke i povećala učinkovitost.

U ovom radu će se najprije definirati osnove skladišnih sustava te navesti da postoje klasična skladišta i automatizirana skladišta. Zatim će biti objašnjene vrste klasičnih skladišnih sustava s posebnom pažnjom na visokoregalna VNA (eng. Very Narrow Aisle) skladišta. Takve vrsta skladišta korisne su zbog svoje uštede prostora.

Nakon toga bit će objašnjeni automatizirani skladišni sustavi s posebnim naglaskom na Person-on-board sustave i band heuristiku određivanja redoslijeda posjećivanja lokacija prilikom komisioniranja.

Svrha ovog rada je prikazati razlike između klasičnih i automatiziranih skladišta te ukazati na prednosti i nedostatke. Nemaju sva poduzeća mogućnost (preveliki trošak), a niti potrebu uvesti automatizirana skladišta, ali prirodno je da je glavna prednost tih skladišta brzina što je sa sadašnjim stanjem tržišta i najbitnija karakteristika. Glavni zadatak rada je analizirati mogućnost primjene heuristika problema trgovačkog putnika (eng. Traveling Salesman Problem, TSP) u visokoregalnim VNA skladištima u kojima se odvija proces komisioniranja s više lokacija unutar jednog ciklusa.

Najprije će se odrediti vrijeme vožnje komisioniranja kada se viličar kreće klasično tako da najprije posjeti sve lokacije koje su najbliže po  $x$  osi, nakon toga će se upotrijebiti spomenuta band heuristika pa heuristički algoritam najbližeg susjeda te na kraju kombinacija band heuristike i TSP-a preko algoritma najbližeg susjeda tj. prvo će se u gornjoj polovici regala

posjetiti sve lokacije po algoritmu najbližeg susjeda te nakon toga, isto tako u donjoj polovici regala.

Da bi se dobili relevantni rezultati, ispitivanje je potrebno vršiti na slučajno odabranim lokacijama unutar regala te na različitim veličinama regala. Budući da jedno ispitivanje nije dovoljno u programu 'Eclipse' napraviti će se 10 000 testova čiji će se rezultati kasnije prikazati. Isto tako, ispitivanje će se vršiti u slučaju kada se viličar kreće sa istovremeno uključenim brzinama u smjeru osi x i u smjeru osi y te u slučaju kada je prvo uključena brzina za kretanje u jednom smjeru i nakon toga u drugom.

Na kraju će se dati usporedba rezultata dobivenih za sve vrste regala, količine narudžbi i kretanja viličara unutar regala.

## **2. Osnove skladišnih sustava**

### **2.1. Osnove klasičnih skladišnih sustava**

Klasični skladišni sustavi podrazumijevaju funkcioniranje, skladištenje, komisioniranje i ostale skladišne procese koji obuhvaćaju međusobnu interakciju klasičnih komponenti (objekti površine, sredstva za skladištenje, sredstva za odlaganje, transportna sredstva, pomoćna skladišna oprema i dodatna skladišna oprema) u skladišnom sustavu.

U širem smislu skladište je ograđeni ili neograđeni prostor, pokriveni ili nepokriveni, koji se koristi za čuvanje sirovina, poluproizvoda ili gotovih proizvoda koji su u funkciji odvijanja poslovnih procesa u poduzeću.

U užem smislu skladište podrazumijeva mjesto smještaja, čuvanja i izdavanja robe.[1]

Skladišta su izgrađeni objekti ili pripremljeni prostori za smještaj i čuvanje roba od trenutka njihovog preuzimanja do vremena njihove upotrebe i otpreme. To je mjesto u kojem su pohranjene zalihe te je uređeno i opremljeno za privremeno i sigurno odlaganje, čuvanje, pripremu i izdavanje materijala.

S logističkog stajališta skladište je čvor ili točka na logističkoj mreži na kojem se roba prije svega prihvaća ili prosljeđuje u nekom drugom smjeru unutar mreže.

Glavna tehnička funkcija skladišta je odvijanje procesa skladištenja i distribucije, a cilj skladišta je osigurati prostorno i vremensko uravnoteženje tokova materijala unutar samog objekta nekog poduzeća, između dva ili više objekata poduzeća, te između dva ili više različitih poduzeća unutar logističkog lanca. [2]

Sa stajališta proizvodnje, svako skladištenje, odnosno mirovanje materijala predstavlja prekid procesa što je u pravilu nepovoljno jer produljuje ciklus proizvodnje.

### **2.2. Analiza postojanja skladišta**

Skladištenje je posljedica stupnja razvoja, uvjeta, koncepcije i organizacije poslovanja, a može se eliminirati djelomice ili u cijelosti, promjenama u poslovnom procesu (u poduzeću i odnosima u okruženju – logističkom lancu).

Uvjetovano je djelatnošću poduzeća ili potrebama proizvodnog procesa i ne može se ukloniti. Posljedica je utjecaja okruženja poduzeća bez mogućnosti izravnog utjecaja.

Skladište predstavlja tehnički organiziran i funkcionalan skladišni sustav te u skladu s time postoje sljedeće komponente skladišnog sustava [2]:

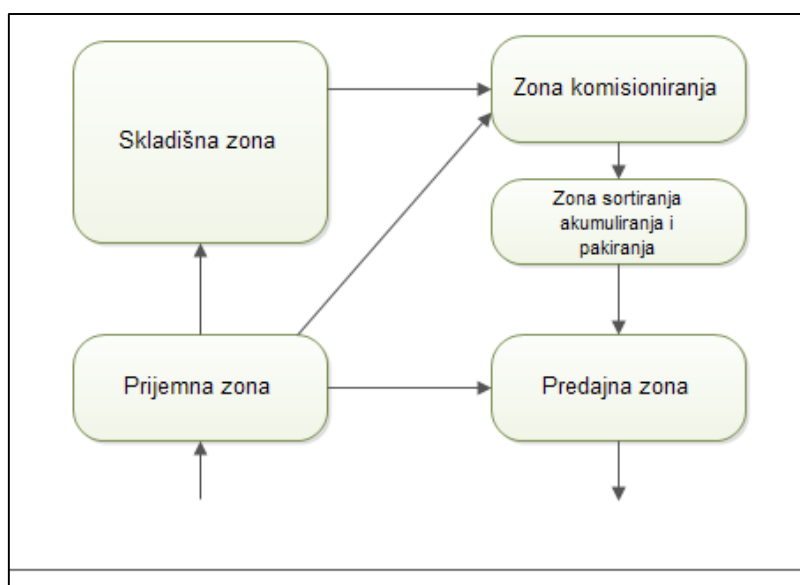
- Objekti/uređene površine
- Sredstva za skladištenje
- Sredstva za odlaganje
- Transportna sredstva
- Pomoćna skladišna sredstva
- Dodatna skladišna sredstva

### 2.3. Skladišne zone

U skladištu postoje 4 osnovne zone, a to su prijemna zona, skladišna zona, zona komisioniranja i predajna zona. Skladišni proces su sve aktivnosti unutar i između zona.

U skladu s time postoje 4 osnovna podprocesa: prijem, uskladištenje, komisioniranje i izdavanje.

Na slici 1 prikazane su 4 skladišne zone. Roba se preuzima u prijemnoj zoni nakon čega postoje dvije mogućnosti. U slučaju da se ne treba odmah upotrijebiti ide u skladišnu zonu, a u slučaju da je odmah potrebna, preskače skladišnu zonu i dolazi u zonu komisioniranja. Isto tako, roba iz skladišne zone odlazi u zonu komisioniranja, a iz zone komisioniranja odlazi u predajnu zonu gdje se izdaje.



Slika 1. Skladišne zone



Klasični (tradicionalni) sustavi i u skladišnoj i u predajnoj zoni podrazumijevaju tradicionalan izgled skladišta.

U većini industrijskih postrojenja danas, implementiran je takav izgled skladišta. Klasična skladišta su pravokutna sa paralelnim ravnim prolazima između regala. [3]

Klasični skladišni sustavi se razlikuju s obzirom na namjenu skladišta, veličini investicije, proizvođaču, potrebi te mnogim drugim osobinama, ali su komponente gotovo uvijek iste.

Najbitnija komponenta je sredstvo za skladištenje pa se tako skladišta razlikuju [2]:

1) s obzirom na to postoji li sredstvo za skladištenje:

- bez sredstva za skladištenje (podna skladišta)
- sa sredstvima za skladištenje (regalna skladišta)

2) jesu li pokretni ili nepokretni

- s nepokretnim regalima (statična)
- s pokretnim regalima (dinamična)

3) s obzirom na vrstu regala

- polični regali
- paletni regali
- konzolni regali
- prolazni regali
- protočni regali
- pokretni regali
- prijevozni regali

## **2.4. Osnove automatiziranih skladišnih sustava**

Prema američkoj logističkoj organizaciji MHIA (eng. Material Handling Institut of America) automatizirani skladišni sustav (eng. AS/RS - Automated storage/retrival system) obuhvaća razne izvedbe (metode) računalom upravljalog automatiziranog odlaganja i izuzimanja iz skladišnih lokacija tj. takvi skladišni sustavi funkcioniraju da se osnovni procesi odvijaju bez

čovjekovog fizičkog prisustva. Funkcija čovjeka je održavanje i nadzor upravljačkog računala koji nadzire sve procese te upravlja čitavim skladišnim sustavom.

U užem smislu, 1990-ih AS/RS je sustav regala, svaki red ima svoju jedinicu za odlaganje/izuzimanje koja se kreće vertikalno i horizontalno uzduž regala odlažući i izuzimajući terete.

Automatizirani skladišni sustavi imaju 3 primarne funkcije, a to su: skladištenje, ulaz/izlaz tereta u sustav i komisioniranje.

Postoje različiti tipovi izvedbi automatiziranih skladišnih sustava, a najčešći su navedeni u nastavku [2]:

### **1) Horizontalni karuseli**

### **2) Vertikalni karuseli**

**3) VLMS** – vertikalni podizni moduli (eng. Vertical Lift Module System) su skladišni sustavi koji se sastoje od dvije paralelne kolone s fiksnim policama u kojima su uskladišteni spremnici (kutije ili ladice). Odlaganje i izuzimanje spremnika obavlja automatski uređaj (eng. shuttle/extractor), koji se kreće vertikalno između kolona s policama.

**3) Crane-in-aisle AS/RS** - automatizirani skladišni sustavi sa dizalicom unutar prolaza (eng. Crane-in-aisle) između regala. Prema vrsti, i dimenzijama jediničnih tereta postoje sljedeće vrste automatiziranih sustava sa dizalicom unutar prolaza između regala:

- unit-load AS/RS – za jedinične terete
- mini-load AS/RS – za jedinične terete manjih dimenzija
- micro-load AS/RS – za jedinične terete vrlo malih dimenzija
- person-on-board AS/RS – polu-automatizirani skladišni sustavi -> sustav sa dizalicama na kojima se nalazi čovjek koji vrši izuzimanje.

Prednosti automatiziranih skladišnih sustava su povećavanje iskoristivosti skladišnog prostora, povećana kontrola zaliha i praćenje zaliha, smanjenje troškova ljudskog rada, povećava se sigurnost na radu, povećana zaštita materijala te točnost operacija.

Nedostaci su visoki investicijski troškovi, povećani zahtjevi održavanja, povećani zahtjevi za tolerancije i nefleksibilnost.

### 3. Pregled osnovnih regala u klasičnim skladišnim sustavima

U ranijem poglavlju prikazana je klasifikacija skladišnih sustava s obzirom na sredstva za odlaganje te slijedi popis pojedinih vrsta regala i njihove primjene u klasičnim skladišnim sustavima.

#### 3.1. Podna skladišta

Podna skladišta (eng. Floor storage block) su učinkovita kada postoji više paleta po jedinici odlaganja - SKU (eng. Stock Keeping Unit). Zalihe se uvelike povećavaju tj. više tereta iste jedinice se prima i izuzima u isto vrijeme. Glavni problem je gubitak mjesta zbog toga što se izuzima kutija po kutija pa na kraju izgleda kao probušena pčelinja saće i neučinkovito je iskorištena vertikalna dimenzija objekta. [2]

Glavne prednosti slaganja u blokove su niži glavni troškovi, nema potrebe za opremom za slaganje zaliha i dobra je iskoristivost prostora iako ne nužno u visinu. Lagano se kontrolira te su pogodni za visoku propusnost.

Nedostaci slaganja u blokove su ograničenja na visinu gomile (bloka). Slobodan pristup je samo do paleta koje su na vrhu reda i rizik od požara.

Prikaz podnog skladišta dan je na slici 2.



Slika 2. Podno skladište

### 3.2. Skladišta sa paletnim i poličnim regalima

Skladišni sustavi sa poličnim regalima su sustavi čiji se proces skladištenja i izuzimanja vrši na taj način da se komisioniraju samo jedinični tereti koji su odloženi za na to predviđeno mjesto – policu ili spremnik. Ti su sustavi ekonomični i najbolji kada je riječ o manjim narudžbama jer tada ima manje izuzimanja po stavci te kod vrlo malih proizvoda. [2]

Kod paletnih regala materijal se odlaže uz primjenu posebne opreme (paleta) i obvezno pomoću transportnog sredstva – viličar.

Prikaz paletnih regala je na slici 3.



**Slika 3. Paletni regal**

Polični i paletni reglai najčešće su postavljeni u redove, s odlaganjem jedne palete po dubini. Time je osiguran izravan pristup svakoj jedinici skladištenja.

Kod paletnih regala uobičajene su dvije varijante odlaganja paleta: poprečno i podužno odlaganje.

Iskoristivost skladišne površine je 30-40%, uz moguću iskoristivost skladišnih lokacija do 100%.

Dimenzije klasičnih paletnih regala su najčešće 6-7,5 m širine i do 12(15) m visine

Postoje i paletni regali dvostruke dubine. Glavne prednosti takvih paletnih regala su povećana gustoća skladištenja i učinkovit sustav skladištenja, a nedostaci su što su potrebni viličari sa dvostrukim dosegom. Brzina pristupa svim pozicijama paleta je ograničena i slaba je vidljivost vozača viličara kada prilaze stražnjim lokacijama.

### 3.3. Skladišta s konzolnim regalima

Konzolni regali (eng. Cantilever rack; Long load system) koriste se za skladištenje robe velikih dužina i dimenzija. Najčešće se koriste za željezne cijevi, drvenu građu, ploče, razne profile, limove i dr.

Izvide se kao jednostrani i dvostrani i mogu se koristiti u zatvorenom ili otvorenom prostoru. Također, mogu poslužiti i kao samonosiva konstrukcija kod namjenskih skladišta. Moguće su razne izvedbe, obzirom na visinu regala, te duljinu i opterećenje konzola. Jednostruki konzolni regali uglavnom se postavljaju uz zid skladišta. [4]

Primjenjuju se u industrijskim poduzećima za odlaganje komadnog materijala s jednom ili dvije karakteristične izmjere (šipke, cijevi, profili, paketi limova i sl.). Visine su do 8 m, a duljine konzolnih nosača do 3 m, nosivosti do oko 200kN (25kN po konzoli). Standardne izvedbe su fleksibilne, odnosno stup regala ima raster koji omogućuje promjenu visine pojedinih razina.

Elementi konzolnog regala su: stup regala, konzolni nosač, veznik stupova, dijagonalni veznik i temeljni nosač. Konzolni regal može biti sastavljen od više jedinica regala, ovisno o duljini materijala. Najčešća sredstva za rukovanje komadnim materijalom u konzolnim regalima su podni viličari i granici viličari. [3]

Na slici 4 je prikazan primjer konzolnog regala.



**Slika 4. Konzolni regal**

Prednosti su lako skladištenje i izuzimanje, fleksibilan dizajn – broj i dužina nosača, prostor između stupova i visina može biti dizajnirana da pohrani bilo koji tip, veličinu i težinu materijala.


### 3.4. Skladišta s prolaznim regalima

Prolazni regali (eng. Drive-in, Drive-through rack) služe za pohranu veće količine istovrsnih materijala pomoću posebne opreme (palete, sanduci...). Jednostavnih su konstrukcija, a sastoje se od međusobno povezanih vertikalnih nosača – stupova, na kojima se nalaze nosači paleta. Stupovi su spojeni poprečnim veznicima. Stranice regala su raspoređene tako da oblikuju mjesta za odlaganje i slobodne prolaze transportnom sredstvu koje rukuje jediničnim teretima. Duljine regala su 8-10 jedinica skladištenja po dubini.

Iskoristivost skladišne površine je oko 75%, no popunjenost skladišnih lokacija kreće se oko 60%.

Drive-in prolazni regali su razvijeni sa ciljem redukcije površine za prolaze, a omogućuju skladišne linije dubine do 10 paleta i visine 3-5 jedinica. Konstrukcija omogućava viličaru da se kreće unutar regala do pozicije odlaganja/izuzimanja palete. Nedostaci s znatna redukcija brzine pri kretanju i gubitak kapaciteta. U ovakvim vrstama regala ostvaruje se LIFO strategija (eng. Last in, First out- zadnja paleta koja uđe, prva izlazi).

Na sljedećoj slici prikazan je drive-in regal.




Slika 5. Drive-in regal

Za razliku od standardnih drive-in regala, viličar u drive-trough regalima ima pristup do pojedine palete s dvije strane. Moguće je da se unos paleta u regal vrši s jedne strane, dok se njihov iznos obavlja s druge strane regala. Na taj način se ostvaruje i FIFO princip (eng. First in, First out - prva paleta koja uđe u regal prva i izlazi). [5]



Na slici je prikazan Drive-trough regal.



**Slika 6. Drive-trough regal**

Prednosti prolaznih regala su da visoka gustoća skladištenja omogućuje skladištenje većeg broja paleta po metru kvadratnom nego u drugim skladišnim sustavima. Idealni su za serije paleta, pogodni su za sezonsku robu te idealni su za hladna i ohlađena skladišta. Pogodni su za lomljiv teret koji ne može biti pohranjen u blokovima. Niski su troškovi i nije potreban poseban način rukovanja. Regali su visoki do 10 m bez prolaza.

### **3.5. Skladišta s protočnim regalima**

Protočni regalima (eng. Flow-rack) ostvaruje se dinamičko skladištenje komadnog materijala, kao jediničnog tereta na paletama, u sanducima, kutijama... Takva skladišta pogodna su za odlaganje istovrsnog komadnog materijala većih količina. Najčešće izvedbe su duljine oko 20 m (do 20 jedinica po dubini) i visine 12 m.

Rukovanje materijalom ostvaruje se po FIFO principu koje je objašnjeno u prethodnom poglavlju.

Izraz dinamičko skladištenje je zbog kretanja materijala u takvom regalu, a može biti izvedeno:

- a) voznom stazom bez pogona korištenjem sile teže – gravitacijski regali (kut nagiba 1-5%)
- b) voznom stazom s pogonom – staza je vodoravno postavljena, kretanje materijala brzinom 0,3 m/s pomoću sredstva neprekidnog transporta toka (valjčane, lančane ili

trakaste staze ili pruge), odnosno sredstvima prekinutog transporta posebno izvedenim vozilima koja se kreću ispod jediničnog tereta.

Iskoristivost skladišne površine je oko 75%, a popunjenost skladišnih lokacija je oko 70%.

Postoje i protočni regali s guranjem (eng. Push-back rack), a to su regali sa voznim stazama (valjčani konvejer ili nosači s kotačićima) pod kutom.

Obrnuti su od klasičnih protočnih regala i moguće je ostvariti isključivo LIFO princip skladištenja.

Dubina skladištenja je 2-5 jedinica i zbog manje dubine je relativno velika dostupnost te je dobra iskoristivost površine. [3]

Na slici je prikazan protočni regal.



Slika 7. Protočni regal

### 3.6. Skladišta s pokretnim regalima

#### 3.6.1. Prijevozni regali

Prijevozni regali (eng. mobile/moveable rack) se koriste za skladištenje komadnog materijala, naročito ako je manja učestalost ulaz-izlaz, budući da je potrebno više vremena za izravan pristup materijalu.

Izvedba prijevoznih regala istovjetna je paletnim/poličnim/konzolnim regalima, samo što su prijevozni regali postavljeni na pokretna postolja koja čine pravocrtno kretanje.



Prema načinu kretanja su im i nazivi, razmični i izvlačni. Prema prvoj varijanti jedinice regala pomične su u smjeru paralelno s glavnim putem. Prema drugoj varijanti regali se pomiču poprečno na glavni prolaz. Iskoristivost skladišne površine je 85%, pri čemu je moguća iskoristivost skladišnih lokacija do 100%.

Pokretanje regala ostvaruje se ručno, nekim motornim pogonom ili električnim pogonom korištenjem malih električnih motora koji se pokreću pritiskom gumba. [3]

Na slici je dan prikaz prijevoznog regala.




Slika 8. Prijevozni regal

### 3.6.2. Optočni (okretni) regali

Optočni regali – karuseli sastavljeni su od polica kao elemenata za odlaganje materijala koje se kreću kružno. Kružno kretanje može biti u horizontalnoj ili vertikalnoj ravnini. Tako prema vrsti optoka imamo vertikalne i horizontalne karusele. U njemačkoj literaturi karusel regali su oni sa horizontalnim optokom, a paternoster regali su sa vertikalnim optokom.

Primjenjuju se najčešće za skladištenje materijala manjih težina i dimenzija. Glavna karakteristika, ujedno i prednost im je u potrebi minimalnih podnih površina. Osim toga, zatvorena konstrukcija takvih skladišnih sustava omogućava veliku sigurnost i zaštitu uskladištenog materijala. Također, danas se najčešće koristi ovakav tip skladištenja s automatiziranim procesom skladištenja te se sve više primjenjuje u skladištenju i komisioniranju materijala manjih dimenzija i težina. [3]

Na slici 9 je prikazan okretni regal.



**Slika 9. Okretni regal**

## 4. Visokoregalna skladišta

Visokoregalna skladišta su zapravo klasična paletna skladišta s visokim regalima (danas i preko 10 metara) tako da im je namjena što bolja iskoristivost prostora jer koriste svoju visinu. Zbog svoje visine smanjuje se veličina skladišta i povećava broj lokacija na koje se može spremati pojedini materijal ili što je potrebno odložiti. Samim time povećava se kapacitet skladišta. Ulaganjem u visokoregalna skladišta smanjuju se troškovi održavanja i troškovi skladištenja. Glavni nedostatak visokoregalnih skladišta su veliki investicijski troškovi tako da si ih ne mogu svi priuštiti. Većinom se koriste u velikim i dobrostojećim tvrtkama i velikim distribucijskim centrima koji opskrbljuju jedno cijelo geografsko područje jer se njima isplati ulagati u takva skladišta jer će im se vrlo brzo vratiti uloženo.

Naziv visokoregalnog skladišta dobivaju ona skladišta čija je visina regala iznad 10 metara premda su visine u praksi i puno više. Većina visokoregalnih sustava danas je automatizirana te se njima upravlja nekim složenim računalnim sustavom.

### 4.1. Odluka o širini prolaza

U posljednjih nekoliko desetljeća upravljanje skladišnim sustavima se sve više fokusira na povećavanje brzine komisioniranja i rukovanja materijalom, a manje na skladištenje i gustoću skladišta. Tvrtke koje su prije proizvodile 6-omjesečnu zalihu proizvoda, čuvali ih u gustim skladištima kao što su podna skladišta ili prolazna skladišta te nakon toga otpremale pune kamione robe sada proizvode dvotjednu zalihu i šalju po jednu paletu, kutiju ili dio proizvoda kupcu. Dakle roba na skladištu sada stoji najviše 2 tjedna. To ne umanjuje potrebu za skladištima ili važnost iskoristivosti prostora. Karakteristike skladišta se mijenjaju na taj način da proizvedeni materijal više ne stoji na skladištu već se nastoji što prije otpremiti što dovodi do povećanja kapaciteta skladišta te povećanja protoka materijala. Na mjesto starog proizvoda dolazi nova roba koja će vrlo brzo biti zamijenjena novijom. [6]

Određivanje optimalne širine između prolaza je kritični dio cjelokupnog procesa projektiranja skladišnog sustava. O tome ovisi sveukupna strategija skladištenja i rukovanja materijalom unutar skladišta te mogućnosti i komisioniranje u skladištu. Širina prolaza bi trebala biti takva da ostvaruje najbolju kombinaciju produktivnosti, iskoristivosti prostora, fleksibilnosti, sigurnosti i troškova opreme za posebnu primjenu. Pretpostavka da je širina prolaza koja se oduvijek koristila ili koju drugi koriste ispravna te odgovarajuća za neki tip skladišnog sustava

zapravo je pogrešna i može dovesti do povećanja troškova. Određivanje najbolje širine prolaza je ono što može dovesti do uštede i povećanja iskoristivosti skladišta.

Primarna ograničenja kod određivanja širine prolaza su:

- vrsta viličara koji će se koristiti
- karakteristike robe koja se pohranjuje


Budući da se karakteristike robe koje se pohranjuju ne mogu značajno mijenjati, odluka o širini prolaza zapravo leži u odluci kojom će se opremom vršiti komisioniranje odnosno vrsti viličara.

## 4.2. Tipovi prolaza s obzirom na njegovu širinu

Širina prolaza direktno utječe na izbor transportnih sredstva koji će vršiti komisioniranje u tom skladištu jer se po veličini prolaza određuje kojim će se tipovima transportnih sredstva (viličarima) raditi te se po njihovim karakteristikama odlučuje koji je optimalan za to skladište. Razni proizvođači prema širini prolaza konstruiraju viličare koji su pogodni za određenu širinu. Viličari se određuju prema vrsti prolaza, a postoje 3 osnovne vrste prolaza:

- široki prolaz (eng. Wide aisle – WA)
- uski prolaz (eng. Narrow aisle – NA)
- vrlo uski prolaz (eng. Very narrow aisle – VNA)


Široko prolazni viličari (eng. wide aisle –WA) predstavljaju standard za pojam 'viličar' i oni su najčešće standardni čeonii viličari. Širine njihovih prolaza su između 3,35 m i 3,65 m dok je dubina lokacije za skladištenje oko 1,2 m. Prikaz širokog prolaza prikazan je na slici 10.



Slika 10. Prikaz širokog prolaza

Usko prolazni viličari (eng. narrow aisle – NA) rade u prolazima čije su širine između 2,4 m i 3 m. To je primarno standard viličara s dohvatnim vilicama i uvlačnim jarbolom.

Prikaz uskog prolaza dan je na slici 11.



**Slika 11. Prikaz uskog prolaza**

Vrlo uskoprolazni viličari (eng. Very Narrow Aisle – VNA) –dalje u tekstu VNA viličari- uglavnom rade u prolazima čije su širine manje od 1,8 m. Viličari koji se koriste u takvim prolazima su viličari sa zakretnim vilicama, visokoregalni viličari/viličari komisioneri. Često koriste sustav vođenja (žice, tračnice, optički kabeli) za vožnju unutar prolaza. Vrlo uski prolaz prikazan je na slici 12.



**Slika 12. Prikaz vrlo uskog prolaza**

VNA viličari mogu biti sa čovjekom na viličaru koji vrši komisioniranje na lokaciji (eng. man-up) i čovjekom koji nije na viličaru tj. koji upravlja viličarem sa sjedišta vozila (eng. man-down).

Standardni VNA viličari su sa čovjekom gore koji vrši ručno komisioniranje na skladišnoj lokaciji kod tereta koji nisu jako teški i sa čovjekom gore koji vrši komisioniranje jediničnih tereta. Oni viličari koji vrše komisioniranje jediničnih tereta najčešće mogu vršiti ručno komisioniranje lakših tereta na lokaciji.

Najznačajnija razlika između VNA viličara i svih ostalih viličara je da VNA viličari mogu okretati samo teret, a širokoprolazni i uskoprolazni viličar moraju okrenuti cijelo vozilo. VNA viličari s čovjekom na vozilu (man-up) omogućuju učinkovit rad na velikim visinama za razliku od ostalih viličara koji to ne mogu.

### **4.3. Uštede prostora u skladištima sa uskim i vrlo uskim prolazima**

Primjenom uskih i vrlo uskih prolaza mogu se postići značajne uštede prostora kod primjerice projektiranja novog skladišta tj. kod postojećeg skladišnog sustava može se povećati skladišni kapacitet te bi se u tom slučaju moglo skladištiti više tereta.

Prilikom izračuna potencijalne uštede prostora u obzir se moraju uzeti mnogi faktori.

Faktori koji se trebaju uzeti u obzir uključuju:

- specifikacije vozila
- veličina tereta
- težina tereta
- visina stalka
- faktori održavanja (dimenzije skladišta, struktura skladišnog sustava i potpora održavanju skladišnog sustava).

Kako bi se dala okvirna usporedba uštede prostora u skladišnim sustavima sa uskim i vrlo uskim prolazima naveden je primjer skladišta čiji skladišni regal dimenzija skladišnih lokacija 1000 x 1200 mm koji može podnijeti teret do 6,67 kN. Kada bi se takav tip skladišnog regala koristio u standardnim izvedbama skladišnih sustava sa širokim prolazom (3,35 do 3,65 m) tada bi taj skladišni sustav imao neki definirani kapacitet pohrane tereta prema zahtjevima za koje je konstruiran. Često se javlja potreba za unapređenjem skladišnih sustava i poboljšanjem skladišnih procesa. Glavni problem koji se često javlja kod industrijskih skladišta vezan je za povećanje produktivnosti tako da se poveća kapacitet skladišta. Kako bi se povećao kapacitet skladišnog sustava, najpogodnije je rekonstruirati postojeće skladište u skladište sa užim prolazima između regala.

Uštede prostora uvođenjem regala sa uskim prolazima ( NA - 2,4 do 3 m) povećale su se, odnosno u takvim se skladištima može pohraniti 20%-25% više proizvoda u odnosu na

skladišne sustave sa širokim prolazima. U skladišnim sustavima sa vrlo uskim prolazima (VNA <1,8 m) kapacitet se povećao za 40%-50%.

Da bi se postigle promjene, odnosno izvršilo rekonstruiranje, potrebna je investicija u nova transportna sredstva kao i sustave za navođenje, a to je nešto na što većina tvrtki nije spremna.

#### **4.4. Produktivnost, fleksibilnost, sigurnost i troškovi**

Prema ranije navedenim uštedama prostora kod skladišnih sustava sa uskim i vrlo uskim prolazima, nameće se misao da bi sva skladišta trebala biti projektirana sa užim prolazima, no to nije uvijek tako.

Skladišta postaju sve više usmjerena na produktivnost i kod tržišta koje se sve brže mijenjaju, fleksibilnost i troškovi su pod povećalom, ali ne smije se zaboraviti na sigurnost.

Činjenica je da su standardni viličari koji se koriste kod skladišta sa širokim prolazima i dalje izvediva opcija i imaju svoje prednosti. Fleksibilnost izuzimanja i odlaganja tereta iz paletnog regala, brza vožnja, niski troškovi i kapacitet podnošenja velikih opterećenja su glavne prednosti standardnih viličara i još će neko vrijeme sigurno biti glavni u komisioniranju

Široki prolazi također pružaju veću fleksibilnost kada je riječ o komisioniranju tereta različitih težina i opterećenja.

Uski prolazi među regalima i prolazi sa dvostrukim dubinama omogućuju veću gustoću pohrane sa samo malim ulaganjima u opremu tj. troškovi investiranja u opremu ostaju niski odnosno ne mijenjaju se značajno. Kod takvih prolaza mogu se primjenjivati viličari koji mogu vršiti komisioniranje na visokim regalima. Nedostaci skladišnog sustava sa uskim prolazima u odnosu na one sa širokim prolazom su manje brzine transporta, sporije izuzimanje i odlaganje tereta, složenije linije po kojima se kreće viličar te nemogućnost korištenja prikolica.

Iako viličari rade na velikim visinama, teško je izuzimati i odlagati teret kada se čovjek nalazi u viličaru za upravljačem. Kako bi se smanjili nedostaci koriste se razni senzori za određivanje visine te senzori za kontrolu nagiba. Na taj se način nastoji povećati produktivnost i smanjiti umor vozača. I sa ovim pomagalima, kada vozači s poda gledaju u visinu dok vrše komisioniranje, imaju poteškoća s bolovima u vratu i naprezanjem očiju. To može dovesti do potencijalne štete proizvoda, a i sigurnost vozača koji vrši komisioniranje se treba pažljivo osigurati u tim uvjetima.

Unatoč tome, skladišta sa vrlo uskim prolazima (VNA) su sve više popularna.

Viličari koji se izrađuju tako da čovjek bude u kupoli te na licu mjesta vrši komisioniranje omogućuje veći broj izuzetih i odloženih jediničnih tereta te na taj način takva skladište imaju veću produktivnost od skladišnih sustava sa širokim i uskim prolazima.

Zbog velike gustoće jediničnih tereta moguće je ostvariti brži pristup lokaciji koju je potrebno posjetiti. VNA skladišni sustavi moraju imati sustave senzora te sustave za navođenje transportnih vozila jer se na taj način osigurava točnost kretanja što rezultira većim brzinama kretanja te samim time bržim transportom.

Najveći nedostatak takvih skladišnih sustava su visoki troškovi. VNA viličari komisioneri zajedno sa sustavom navođenja koštaju puno više nego transportna sredstva koja se koriste kod širokih i uskih prolaza. Jedan od razloga njihove visoke cijene su finije tolerancije i mala odstupanja koja se moraju postići kod takvog skladištenja. Upravo zato se VNA skladišni sustavi najčešće konstruiraju kada je riječ o novom projektu, a ne kada je riječ o rekonstrukciji (prenamjeni) postojećeg skladišnog sustava. Iako su investicijski troškovi visoki, uštede koje se postižu na prostoru i povećanje produktivnosti može brzo nadoknaditi te troškove. Iz tog kuta gledanja glavni nedostatak – visoka cijena – i nije više tako velika prepreka.

Sigurnost operatera, kada je riječ o čovjeku na viličaru, je i dalje jedna od najvećih briga. U takvim uvjetima nužno je osigurati uporabu sigurnosnih pojaseva ili remenja.

Donošenje odluke o širini prolaza nije jednostavna odluka i traži angažiranost i vrijeme potrebno za donošenje odluke. Potrebno je napraviti dobru procjenu sustava kako bi se pronašao kompromis između produktivnosti, kapaciteta troškova i fleksibilnosti. [6]

#### **4.5. VNA transportna sredstva**

Transportna sredstva su dizajnirana po tipovima prolaza u kojima vrše komisioniranje. Glavna razlika široko prolaznih viličara i usko prolaznih viličara u odnosu na vrlo uskoprolazne viličare je da se prva dva mogu okretati u prolazu dok se vrlo uskoprolazni ne može. [7]


Osnovna razlika klasičnih i VNA viličara je u tome da se klasični kreću paralelno sa regalima i kada dođe na mjesto gdje se vrši izuzimanje/odlaganje zakreće se tako da stoji okomito na skladišnu lokaciju i vrši komisioniranje. Kod takvih su viličara vilice fiksno orijentirane prema naprijed i viličar se mora okrenuti da bi mogao obaviti svoju zadaću. Kako su kod VNA viličara prolazi vrlo uski, nema mjesta za okretanje pa se u tom slučaju, kada viličar dođe do skladišne lokacije, zakreće samo vilica. Osim što su takvi viličari prilagođeni za širinu prolaza, prilagođeni su i kada je riječ o komisioniranju na većim visinama. Kao što je već prethodno navedeno postoje viličari u kojima je omogućeno da se zajedno sa vilicama do skladišne



lokacije vozi i operater (man-up). Tada je moguće ručno komisioniranje ako je riječ o lakšem teretu.

Dva su sustav vođenja vrlo uskoprolaznih viličara trenutno najzastupljenija na tržištu: električno vođenje pomoću žice i mehaničko vođenje.

Žični sustav vođenja je pouzdan i točan. Glavne značajke su preciznost, određivanje točne lokacije signala, mjerenje visine, dužine i kuta pomoću frekvencije žice. Žično usmjeravanje omogućuje vozilu da odredi glavni put, upravljajući vozilom prema žici pod kutom od 70 stupnjeva. Pogodan je za sva vozila koja zahtijevaju preciznu orijentaciju položaja i kretanje na većim brzinama.[8]



Slika 13. Žični sustav vođenja

Kod mehaničkog vođenja, viličari su opremljeni sa valjcima uz pomoć kojih su vođeni unutar prolaza koji je opremljen vodilicama

Vrlo uskoprolazni viličari prema tipu izvedbe po engleskoj literaturi su [2]:

- viličari sa zakretnim vilicama (eng. turret trucks (man-down/man-up))
- viličari sa zakretnim jarbolom (eng. swing mast)
- viličari sa zakretnom prednjom osovinom/zglobni (eng. articulated truck).

#### **4.5.1. Viličari sa zakretnim vilicama**

Viličari sa zakretnim vilicama (eng. turret trucks) su idealno rješenje u skladišnim sustavima u kojima je prostor ograničen i roba se pohranjuje na vrlo visokim regalima. Glavna prednost ovih viličara je to da nije potrebno okretati cijeli stroj već samo vilice zauzimaju traženi položaj i vrše odlaganje i izuzimanje, pri tome stabilnost i nosivost nije ugrožena. Upravo zbog ušteda u prostoru, ovakvi se viličari vrlo često koriste. Najčešće se upotrebljavaju u skladišnim sustavima sa vrlo uskim prolazima, čak manjima od 1,8 m.

Kao što je već navedeno, postoje dvije izvedbe ovog viličara: man-up i man-down. Kod man-up viličara sa zakretnim vilicama, operater sjedi u kupoli koja je pomična i nalazi se na visini komisioniranja. Operater vrši komisioniranje na samoj lokaciji što smanjuje vrijeme i time povećava učinkovitost. [9]

Man-down viličar se razlikuje po tome što je njegova kabina nepomična. Operater se nije u mogućnosti podići sa svog mjesta već se samo vilica diže. Zbog toga se gubi preciznost pri komisioniranju na samoj lokaciji. [9]

Na slici su prikazani viličari sa man-up i man-down izvedbama.



Slika 14. Viličar sa zakretnom vilicom

#### ***4.5.2. Viličari sa zakretnom prednjom osovinom***

Glavna prednost viličara sa zakretnom prednjom osovinom (eng. articulated truck) je upravo mogućnost zakreta prednje osovine što se očituje kod rada u vrlo uskim prolazima. Takvi su viličari većinom konstruirani kako za zatvorena tako i za otvorena skladišta. Korištenjem takvih viličara u skladišnim sustavima povećava se kapacitet skladišta za 50%.

Nedostatak ovih viličara je nepreglednost pri komisioniranju na većim visinama jer je kabina nepomična te se time smanjuje vidljivost. Zbog velikih brzina na kojima rade ovi viličari mogu se pojaviti značajne štete. [10]



Slika 15. Viličar sa zakretnom prednjom osovinom

#### **4.5.3. Viličari sa zakretnim jarbolom**

Viličari sa zakretnim jarbolom (eng. swing mast) su kombinacija prethodna 2 opisana viličara. Izgled im je sličan viličaru sa zakretnom prednjom osovinom dok je način rada sličan viličarima sa zakretnim vilicama. Zakretni jarboli se mogu zakrenuti za 180 stupnjeva.

Prednosti takvih viličara je da mogu raditi i u zatvorenim i u otvorenim skladištima te se mogu koristiti za utovar i istovar kamiona. Nisu jeftina investicija i zbog brzina koje postižu mogu se pojaviti štete na samom viličaru, a to su glavni nedostaci ovog viličara. [11]



**Slika 16. Viličar sa zakretnim jarbolom**

## 5. Automatizirani skladišni sustavi

Automatizirani skladišni sustavi (eng. Automated storage/retrieval systems) su skladišni sustavi čiji se procesi odvijaju na potpuno automatiziran način tj. bez prisustva čovjeka. U današnje vrijeme sve više tvrtki (koje si to mogu priuštiti) nastoje prenamijeniti svoja skladišta u automatizirana jer takva su skladišta pouzdana, točna i precizna u bilo koje doba dana dok ljudska koncentracija pada i ne mogu neprekidno raditi.

„Automatizirano skladište“ nije cjelokupan skladišni sustav već samo jedan njegov dio (skladišna ili skladišno-komisiona zona).

Prvi AS/RS sustavi su napravljeni kasnih 1960-ih godina te su bili teški, spori i vrlo komplicirani za upotrebu. Današnja tehnologija je pouzdana, brza i smanjenje troškova je primarni kriterij u konstruiranju takvih sustava. Može raditi neprestano (24 sata dnevno, 7 dana u tjednu). [15]

Već ranije je navedena podjela automatiziranih skladišnih sustava, a u idućim poglavljima oni će biti detaljnije objašnjeni.

Komisioniranje se vrši po principu „čovjek robi“ ili „roba čovjeku“.

U komisioniranju prema principu „čovjek robi“ (eng. picker-to-part) komisioner se kreće, hodajući ili vozeći se na transportnom sredstvu, do lokacije sa koje treba izuzeti materijal. Kako se aktivnost izuzimanja najčešće obavlja u prolazima između regala, ova grupa sustava se često naziva i sustavi „u prolazima“ (eng. in-the-aisle). [2]

U sustavima komisioniranja prema principu „roba čovjeku“ (eng. part-to-picker) materijal koji treba izuzeti kreće se do komisionera. Mjesto izuzimanja nalazi se na kraju prolaza pa se ovi sustavi još nazivaju i sustavi „na kraju prolaza“ (eng. end-of-aisle). [2]

Brojne su prednosti AS/RS sustava. Prema BMH (Bastian Material Handling) svjetskoj vodećoj tvrtki za skladišne sustave prednosti AS/RS-a su [15]:

- Smanjenje čekanja, hodanja i traženja lokacija donošenjem robe operatoru
- Povećanje produktivnosti operatora - sustav komisioniranja po principu roba čovjeku (eng. Part-to-picker) je tri do pet puta produktivniji od načina kada operater mora doći do lokacije da bi izvršio komisioniranje.
- Omogućuje praćenje procesa u realnom vremenu sa skoro 100% točnošću
- Povećava kvalitetu proizvoda i produktivnost općenito – informacije u realnom vremenu omogućuju brži odgovor na poteškoću što dovodi do boljih procesa gdje se

vrijeme može trošiti na poboljšanje kvalitete procesa umjesto ubrzavanja samog procesa.

### 5.1. Horizontalni karuseli

Horizontalni karuseli su automatizirani optočni/okretni regali koji se sastoje od fiksnog broja skladišnih kolona odnosno odjeljaka koji su mehanički povezani pogonskim mehanizmom u zatvorenoj petlji. Rade po principu „roba čovjeku“. Svaka kolona dodatno je podijeljena na fiksni broj skladišnih lokacija (polica). Odlaganje i izuzimanje se vrši ručno ili automatski, a okretanje karusela je u većini slučajeva automatizirano.



**Slika 17. Horizontalni karusel**

Glavne prednosti primjene horizontalnih karusela su ušteda vremena i prostora. To se očituje tako što se primjenom horizontalnih karusela smanjila potreba za hodanjem što je dovelo do veće produktivnosti i potencijalnog smanjenja sati rada. Operateri mogu obavljati druge dužnosti poput papirologije, vaganja i brojenja dok karusel dovodi tražene artikle. Još jedan pokazatelj uštede vremena je da jedan operater može raditi s više karusela u isto vrijeme.

Ušteda prostora očituje se tako što je pristup karuselu omogućen samo na jednom kraju, a ne uzduž cijele strane regala (kao kod poličnih regala). Na taj način nekoliko karusela može biti poslagano jedan uz drugi čime se uklanjaju prolazi i štedi se na podnom prostoru.

Visoki karuseli (3-3,5 m) mogu biti korišteni s podiznim stolovima ili vertikalnom automatskom dizalicom (S/R). Horizontalni karuseli mogu se postaviti jedan na drugi te koristiti podest za operatera tj. automatsku dizalicu, čime se dobiva još veća iskoristivost prostora.

Još jedna prednost takvih karusela je mogućnost računalnog upravljanja. Danas se horizontalni karuseli nalaze povezani u skupine od dva, tri ili četiri stroja koje kontrolira upravljačko računalo. Jedan operater radi sa jednom takvom skupinom. Takva vrsta karusela ima veću primjenu u distribuciji nego u proizvodnji. Postali su strojevi specijalizirani za izuzimanje.

Zbog mehaničke jednostavnosti oni su pouzdani, trajni, tiho rade te zahtijevaju minimalno održavanje. Također, smanjuju umaranje operatera uzrokovano hodaњem unutar skladišta, a nadzornici imaju bolji pregled jer im zaposlenici više ne moraju na dulje vrijeme odlaziti iz videokruga. [2]

Horizontalni karuseli se primjenjuju u montaži kod postrojenja za sklapanje gdje se dijelovi ili polu-skllopovi mogu staviti u karusel na kratko vrijeme između daljnjih operacija sklapanja. U proizvodnji se obično koriste kao kratkotrajna skladišta manjih dijelova, potrošenog alata, rezervnih dijelova i zaliha poluproizvoda koja se mogu nadopunjavati. Stavke u određenim količinama izlaze iz karusela prema zahtjevu, a zahtjevi su uglavnom neplanirani i nisu u seriji sa sličnima.

Sustavi horizontalnih karusela orijentirani su prvenstveno zaprimanju narudžbi i komisioniranju, ostvarujući visoki protok. Najčešće se koriste u distribuciji kod izuzimanja prema narudžbi. Osnovna jedinica sustava horizontalnih karusela je ćelija (pod). Radna ćelija je integrirani radni centar od dva, tri ili četiri povezana karusela pod kontrolom jednog računala koji ostvaruje više razine protoka. Sav alat koji je potreban operateru sadržan je u radnoj ćeliji.


## **5.2. Vertikalni karuseli**

Vertikalni karuseli kao i horizontalni rade po principu „roba čovjeku“.

Sastoje se od fiksnog broja polica koje u zatvorenoj petlji rotiraju u vertikalnoj ravnini. Moguće je automatsko odlaganje i izuzimanje, ali ono je rjeđe nego kod horizontalnih karusela. Vertikalni karuseli su u početku uvođeni radi smanjenja skladišnog prostora potrebnog za skladištenje robe u statičnim klasičnim poličnim sistemima. Čak i sa ograničenom



raspoloživom visinom stropa vertikalni karuseli mogu iskoristiti inače neupotrebljiv zračni prostor. Na slici 18. prikazan je primjer vertikalnog karusela.



**Slika 18. Vertikalni karuseli**

Tražena roba se dovodi direktno pred operatera što rezultira skraćanjem vremena traženja koje mu je ranije bilo potrebno. Velik broj investicija u sustave vertikalnih karusela opravdan je već samim smanjenjem vremena izuzimanja. Svaki vertikalni karusel može biti opskrbljen kao potpuno zatvoren, šesterostrani ormar koji je čist i omogućava izuzetnu sigurnost. Sigurnost se još može povećati mehaničkim i elektroničkim metodama u slučaju da se želi ograničiti pristup određenim spremnicima karusela.


U početku su vertikalni karuseli dizajnirani za pohranjivanje laganih stvari kao što su elektroničke komponente, dijelovi i alat u odjelima za održavanje te dokumenti potrebni za proizvodni proces, a sličnu ulogu imaju i danas u proizvodnim i montažnim odjelima. [2]

Koriste se za čuvanje zamrznutih uzoraka ljudskih stanica, a ponekad čak kao mrtvačnica. Pohranjuje se nakit i vrijedne kovine, a u SAD-u je svaki originalni vrijedni patent spremljen u vertikalnom karuselu. [2]

### 5.3. Vertikalni podizni moduli

Vertikalni podizni moduli (eng. Vertical Lift Module – VLM) su skladišni sustavi koji se sastoje od dvije paralelne kolone s fiksnim policama u kojima su uskladišteni spremnici (kutije ili ladice). Odlaganje i izuzimanje spremnika obavlja automatski uređaj (eng. shuttle/extractor), koji se elevatorom kreće vertikalno između kolona s policama. Sastoji se od tri osnovna, paralelna stupca. Prednji i stražnji stupac koriste se za skladištenje te su opremljeni držačima koji funkcioniraju kao police za spremnike dok se središnjim stupcem kreće dizalo sa napravom za odlaganje i izuzimanje spremnika (inserter/ekstraktor).

VLM je brz i jednostavan način da se iskoristi inače neupotrebljiv prostor u visini, uslijed čega se smanjuje količina podnog prostora za skladištenje.[2]



Slika 19. Vertikalni podizni modul

S obzirom da se materijali odlažu u visini struka, VLM osigurava manju mogućnost ozljeda na radu te eliminira potrebu opasnih radnji kao što je penjanje po ljestvama. Svaki VLM je potpuno zatvoren sa svih šest strana te je zato izuzetno siguran i održava čistoću pohranjene robe. Sigurnost se također može poboljšati korištenjem mehaničkih i elektroničkih metoda uključujući lozinke koje ograničavaju pristup određenim skladišnim lokacijama ili VLM-u u potpunosti.



## 5.4. Crane –in-aisle AS/RS

Automatizirani skladišni sustavi su računalno upravljani strojevi za izuzimanje, čuvanje i odlaganje tereta na točno određenim lokacijama u skladištu

Dizalice u AS/RS sustavima su pouzdane i točene te nadilaze mogućnosti VNA viličara. Suvremene dizalice djeluju unutar skupa gornje i donje tračnice eliminirajući potrebu za zahtjevima s poda. Budući da je dizalica stabilizirana tračnicama, ima veću nosivost i može doseći regale na većim visinama. Imaju visoku učinkovitost vremena ciklusa i izračuna kretanja unutar distribucijskog centra. U ručnim operacijama unutar skladišta, transport proizvoda se vrši samo u jednom smjeru tako da se teret odloži i zatim se transportno sredstvo prazno vraća na početnu poziciju. Dizalice optimiziraju svoje kretnje tako da najprije odlože teret na zadanu poziciju i pri povratku izuzmu teret s druge lokacije u skladištu koja je u blizini. Korištenje dizalica pokazalo se kao održiv način za smanjenje operativnih troškova i troškova distribucije u skladišnim sustavima. Polu automatizirane i automatizirane dizalice smanjuju broj ljudi potrebnih za rad u skladištu. Ugradnjom takvih dizalica u skladišni sustav uvelike se smanjuju troškovi. [12]

U sljedećim poglavljima objašnjene su vrste s obzirom na težine tereta.

### 5.4.1. Unit-load AS/RS

Unit-load je naziv za automatizirano visokoregalno skladište. Sam naziv govori da se svakim teretom rukuje pojedinačno. To je tip sustava automatiziranog odlaganja i izuzimanja za teže tj. veće terete (od 250 do 500 kg i više). Tereti za komisioniranje su smješteni u paletama ili u plastičnim, metalnim ili drvenim sanducima paletnih dimenzija. Nekim velikim teretima može se rukovati i bez sredstava za oblikovanje jediničnog tereta, npr. kolutovi limova, papira, kablova i sl. [2]

Visine tih skladišta su od 10 do 50 m, a duljine prolaza su i do 290 m.

Glavne prednosti skladišta za jedinične terete - unit-load skladišta - su stabilan prijevoz tereta u skladištima velike gustoće, sposobnost obrade različitih vrsta tereta, visoka pouzdanost i raspoloživost, precizno upravljanje zalihama, sigurna pohrana s ograničenom pristupom osoblja, niska potrošnja energije te sigurnost, brzina i tih i uredan rad. [13]

Prikaz unit-load skladišta dan je na sljedećoj slici.



**Slika 20. Unit-load skladišni sustav**

#### **5.4.2. Mini-load AS/RS**

Mini-load je naziv za automatizirano visokoregalno skladište dizajnirano za odlaganje i izuzimanje manjih tereta koji su obično u malim spremnicima (kutijama, ladicama...) s ukupnom težinom između 50 i 250 kg ( rijetko do 500 kg). Ima mogućnost brzog ubrzanja i velike brzine kretanja po trodimenzionalnoj osi. Mogu dosegnuti horizontalnu brzinu do 2,5 m/s i vertikalnu do 0,6 m/s. Visina sustava kreće se između 3 i 15 m, a regali su duljine 12 do 60 m. Idealni su za odlaganje i izuzimanje u skladištima velike gustoće. Komisioniranje se izvodi po principu „roba čovjeku“. [14]

Na sljedećoj slici prikazana je Mini-load skladište.



**Slika 21. Mini-load skladište**

### **5.4.3. *Micro-load AS/RS***

Micro-load automatizirano skladište slično je mini-load skladištu koje je opisano u prethodnom poglavlju. Glavna razlika između navedena dva skladišta je u masi tereta koje jedno odnosno drugo skladište može pohraniti. Mini-load je sustav odlaganja za male proizvode u vrlo malim spremnicima (kutijama ili ladicama) s ukupnom težinom manjom od 50 kg. [2]

### **5.4.4. *Person-on-bord AS/RS***

Person-on-bord AS/RS (eng. man-on-board, person-on-board AS/RS) je sustav komisioniranja po principu „čovjek robi“.

To je (polu)automatizirani sustav odlaganja i izuzimanja s čovjekom na dizalici za ručno uskladištenje i izuzimanje unutar prolaza između visokih poličnih i paletnih regala. [2]

Osnovna karakteristika ovog tipa sustava je da se čovjek nalazi na dizalici te na lokaciji vrši komisioniranje dijelova. Prema tome najčešće se koristi kod komisioniranja lakih tereta.

Ovi sustavi su skuplji nego ostali tipovi AS/RS-a jer zahtijevaju kompleksnu instalaciju budući da se čovjek nalazi na samoj dizalici. Nedostatak u troškovima nadoknađen je uštedama prostora uslijed velike fleksibilnosti i dosega cijelog sustava. U skladišnim sustavima gdje je prostor jako bitan, sa sustavom Person-on-bord može se maksimizirati učinkovitost.

Princip rada samog sustava je da računalo po nalogu operatera upravlja kretanjem dizalice do skladišne lokacije koja se posjećuje. Operater izvrši izuzimanje/odlaganje te na računalu pritisne potvrdu. Nakon toga ga dizalica odvede do sljedeće lokacije. Nakon što posjeti sve lokacije, kabina s dizalicom se vraća na početno mjesto.

Početak i kraj komisioniranja počinje u P/D stanici (eng. Pick-up/Delivery) – pretovarnoj stanici.

Komisioniranje se može obavljati tako da operater uzima jedinični materijal s polica/kutija ili tako da izvuče cijelu paletu pa onda komisionira.

Sustav je opisan kao poluautomatiziran jer S/R dizalica stane ispred skladišne lokacije nakon čega slijedi ručno izuzimanje robe.

Budući da postoji više izuzimanja po ciklusu tj. operater posjeti više lokacija, riječ je o višestrukom radnom ciklusu MC.


Protok sustava (broj izuzimanja po satu) ovisi o očekivanom vremenu ciklusa  $E(MC)$ .

Vrijeme ciklusa ovisi o [16]:

- brzini dizalice
- veličini regala
- obliku regala
- vremenu izuzimanja na lokaciji
- vremenu pražnjenja na P/D stanici
- redoslijedu posjećivanja lokacija – TSP (eng. Traveling Salesman Problem) – problem

trovačkog putnika

Na slici je prikazano komisioniranje po principu Person-on-board.



**Slika 22. Person-on-board komisioniranje**

TSP – problem trgovačkog putnika opisan je na način da je jednom trgovcu dana lista gradova koje mora posjetiti, a u svaki grad smije ući samo jednom. Nakon što obiđe sve gradove, vraća se u početni grad. Javlja se problem kojim putem tj. redoslijedom obići sve gradove tako da ih obiđe u najkraćem vremenu.

Problem redoslijeda posjećivanja lokacije kod Person-on-board isti je kao i kod TSP problema samo što se trgovac kreće horizontalno, dok se dizalica giba vertikalno po regalu.

Redoslijed posjećivanja lokacija može se odrediti na više načina, a u nastavku su prikazani optimalan način i češće korištena Band heuristika.

#### 5.4.4.1. Optimalan redoslijed izuzimanja

Yavuz Bozer je 1985. godine predstavio empirijski model za određivanje vremena vožnje u višestrukom ciklusu.

$$E(t) \approx T \left[ \frac{2n}{(n+1)} + 0.114703 \cdot n \cdot \sqrt{Q} - 0.074257 - 0.041603 \cdot n + 0.459298 \cdot Q^2 \right]$$

$3 \leq n \leq 16$  broj lokacija s kojih se izuzimaju dijelovi

T faktor mjere (skalarni faktor)

Q faktor oblika regala

$$T = \max \left\{ \frac{L}{v_x}, \frac{H}{v_y} \right\}$$

$$Q = \min \left\{ \frac{L}{v_x \cdot T}, \frac{H}{v_y \cdot T} \right\}$$

L – dužina regala

H – visina regala

Pretpostavke njegovog modela su:


- Postoji slučajni raspored odlaganja
- Regal je pretpostavljen kao kontinuirana površina
- Ubrzanja i usporenja su zanemarena
- P/D stanica je u donjem kutu ormara
- Redoslijed izuzimanja/odlaganja je optimalan

Problem koji se u ovom modelu pojavio je preveliko vrijeme računanja računala koji šalje dizalicu na određenu lokaciju.

#### 5.4.4.2. Band heuristika

Osim optimalne metode, za određivanje redoslijeda posjećivanja lokacija, mogu se koristiti i heurističke metode. Jedna od najpoznatijih u Person-on-board sustavima je „band heuristika“ ili „heuristika traka“.

Regal je podijeljen na  $k$  jednako velikih horizontalnih traka, pri čemu je  $k$  paran broj. Počevši od prve (gornje) trake, dizalica se kreće cik-cak (u obliku zmijskog pokreta) po osi  $x$  sve dok ne posjeti sve lokacije u prvoj traci. Na slici 23. je dan prikaz sa 4 trake. Bitno je za naglasiti da S/R dizalica najprije posjeti sve lokacije na trenutnoj traci prije nego prijeđe na sljedeću. Zbog toga, ovisno o broju traka (tj. širini trake), dizalice se kreće cik-cak dok posjećuje sve lokacije. Budući da je riječ o heurističkom modelu, očekivano vrijeme vožnje dizalice bit će veće nego ono dobiveno optimalnim modelom. Međutim, band heuristika je pouzdana i laka za implementirati. Kada je traka manja, manje je i cik-cak kretanja. Viši regali imaju šire trake, što uzrokuje kretanje u cik-cak obliku. [17]



Slika 23. Band heuristika

Broj traka ovisi o broju lokacija -  $n$  - koje se moraju posjetiti po jednoj narudžbi. U tablici je prikazan optimalan broj traka za zadani  $n$ .

**Tablica 1. Optimalan broj traka (za zadani n) [16]:**

Broj izuzimanja n	Broj traka k
1 – 24	2
25 – 72	4
73 – 145	6
146 – 242	8

Ranije spomenuti autor Bozer, napravio je model za aproksimaciju vremena vožnje u višestrukom ciklusu ukoliko je redoslijed izuzimanja po band heuristici. Njegov model prikazan je sljedećim izrazom:

$$E(k, n, T, Q) = T \left[ 2kA + kB(n-1) + \frac{k-1}{k} Q \right]$$

$k$  – broj traka

$$A = \frac{C}{2} + \frac{1 - (1-C)^{n+2}}{C(n+1)(n+2)}$$

$$B = \frac{C}{3} + \frac{2nC + 6C - 2 + 2(1-C)^{n+3}}{C^2(n+1)(n+2)(n+3)}$$

$$C = \frac{Q}{k^2}$$

Prema Bozeru ovi su izrazi optimalni za veličinu narudžbi  $n$  u rasponu od  $3 < n < 24$ .

Glavne pretpostavke kod oblikovanja Person-on-bord sustava su: [16]

- Regali su SIT (eng. square in time) oblika ( $Q=1$ )
- Jedan komisioner (dizalica) u svakom prolazu.

Cilj je minimizirati broj prolaza, a ograničenja su zadani protok i potreban kapacitet.

$S$  – ukupan potrebni kapacitet (izražen kao ukupna površina regala)

$R$  – ukupan protok (izražen kao broj izuzimanja po satu)

$n$  – prosječan broj lokacija po narudžbi, ne uključujući i P/D stanicu (između 3 i 24)

$p$  – prosječno vrijeme izuzimanja po lokaciji, izraženo u minutama

$K$  – vrijeme na P/D lokaciji

$h, v$  – horizontalna i vertikalna brzina dizalice.

Algoritam je povećavati broj prolaza  $M$  dok se ne zadovolje ograničenja.



## 6. Problem usmjeravanja vozila

Problem usmjeravanja vozila (eng. vehicle routing problem – VRP) je općenito ime za cijeli skup problema u kojima je potrebno odrediti skup ruta flote vozila koja su smještena na jednom ili više polazišta (eng. depot) za posjećivanje određenog broja geografski disperziranih lokacija (gradova, korisnika, mjesta u skladištu...) u svrhu dostave i skupljanja robe ili usluga. Cilj rješavanja je pronaći rute s minimalnim troškovima (udaljenosti, vrijeme, broj vozila,...) uz zadani skup ograničenja. [18]

Ovaj problem se prvi put spominje 1959. godine u radu „The Truck Dispatching Problem“ autora Dantziga. i Ramsera čiji je cilj bio organizacija dostave goriva na nekoliko benzinskih crpki. U narednim godinama pojavile su se mnoge heuristike temeljene na raznim principima koje uključuju uštede, geografsku blizinu, povezivanje lokacija kao i poboljšanja u usmjeravanju. Godine 1964. su Clarke i Wright predložili poboljšanje Danzingove i Rasmerove metode konstrukcijom ruta. Njihova heuristika je jedna od najpoznatijih heuristika ušteda koja je izdržala test vremena zbog svoje brzine, jednostavnosti i razumno dobre točnosti. [19]

Rješavali su se isključivo mali problemi koji su uključivali 10 – 20 korisnika. Krajem 60-ih dogodio se bitan pomak uvođenjem 2OPT i 3 OPT mehanizma poboljšavanja ruta. U sedamdesetim je uveden koncept dvoprolaznih algoritama, a sama brzina izvođenja algoritama postaje sve značajnija. Veličine problema koji se rješavaju bitno rastu te su riješeni neki problemi i do 1000 korisnika. U tom razdoblju od 1970. do 1980. neki od problema od 25 do 30 korisnika rješavaju se optimalno. Osamdesetih godina dvadesetog stoljeća započinje brz razvoj egzaktnog rješavanja problema zasnovanog na linearnom programiranju. Osim egzaktnog predlažu se i razvijaju i drugi pristupi rješavanju problema usmjeravanja vozila zasnovani na iskustvu. Optimalno se rješavaju neki od problema s 50 korisnika. Na osnovu mnogo novouvedenih, međusobno bitno različitih metoda, tijekom devedesetih formira se na općem nivou rješavanja optimizacijsko kombinatoričkih problema novi koncept metaheuristike. Problemi usmjeravanja vozila koji se optimalno rješavaju devedesetih dosežu veličinom i do 100.

Primjenom metoda usmjeravanja vozila znatno se smanjuju troškovi transporta. Matematički prikazi su često složeni i nepregledni i zato se koristi znanje iz teorije grafova. Razlog tome je što mnogi od tih koncepata i teorijskih problema proizlaze iz praktičkih razloga, za rješavanje stvarnih problema koji su karakterizirani strukturom grafa odnosno mreže.

Graf se sastoji od točaka (vrhova, čvorova) i linija (bridova) koje ih međusobno povezuju. U teoriji grafova terminologija nije standardizirana, te se i u hrvatskom, kao i u engleskom, koriste

različiti termini: vrh, čvor, točka (eng. vertex, node, point), odnosno brid, ivica, linija, grana, luk (eng. edge, line, arc).

Osim u matematici, primjena teorije grafova može se pronaći u kemiji, kompjuterskim znanostima (računalne mreže), transportnim mrežama, komunikacijskim mrežama, električnim mrežama, financijskom planiranju, sociologiji, teoriji igara, teoriji odlučivanja i sl.

Postoji više problema VRP-a, a najznačajniji su:

- Problem trgovačkog putnika (eng. Traveling Salesman Problem - TSP)
- Problem usmjeravanja vozila s ograničenjima kapaciteta (eng. Capacitated Vehicle Routing Problem - CVRP)
- Problem usmjeravanja vozila s vremenskim ograničenjima (eng. Vehicle Routing Problem with Time Windows - VRPTW)
- Problem usmjeravanja vozila s dostavom i povratnim prikupljanjem (eng. Vehicle Routing Problem with Backhauls - VRPB)
- Problem usmjeravanja vozila s dostavom i prikupljanjem (eng. Vehicle Routing Problem with Pickup and Delivery - VRPPD)
- Problem usmjeravanja vozila s ograničenom duljinom rute (eng. Distance-constraint Vehicle Routing Problem- DCVRP)
- Problem usmjeravanja vozila s više polazišta (eng. Multiple Depot Vehicle Routing Problem - MDVRP)
- Problem usmjeravanja vozila s podijeljenom dostavom (eng. Split-Delivery Vehicle Routing Problem)

U ovom radu obradit će se samo TSP jer će se ta heuristika primjenjivati dalje u radu.

## **6.1. Problem trgovačkog putnika**

Problem trgovačkog putnika (eng. Traveling Salesman Problem – TSP) najjednostavniji je oblik VRP-a, a jedino je ograničenje da postoji samo jedno vozilo (eng. single vehicle routing). U slučaju rutiranja (eng. routing problem) cilj je pronaći redoslijed posjećivanja određenog broja lokacija krenuvši od početne lokacije, a glavna karakteristika je minimiziranje troškova. Vrlo često se vozilo nakon obavljene rute treba vratiti na početnu lokaciju.

Problem trgovačkog putnika definiran je kao problem pronalaženja optimalne rute kroz skup lokacija, na način da se svaka lokacija posjeti isključivo jedanput te se vrati u početnu lokaciju.

Izrečeno terminologijom teorije grafova, neka je  $V$  skup  $n + 1$  vrhova (lokacija)  $V = \{0, 1, 2, \dots, n\}$ , problem je pronaći rutu (ciklus) koji počinje i završava u vrhu 0, a prolazi svim vrhovima od 1 do  $n$  točno jedanput, takvu da je ukupna udaljenost minimalna.[18]

Ruta koja prolazi svim vrhovima grafa i završava u početnom vrhu poznata je kao Hamiltonov ciklus.

Drugim riječima, problem trgovačkog putnika je pronalaženje Hamiltonovog ciklusa minimalne duljine.

Hamiltonov put je put u neusmjerenom grafu koji prolazi kroz sve vrhove grafa isključivo jedanput.

Hamiltonov ciklus je ciklus u neusmjerenom grafu koji prolazi sve vrhove grafa isključivo jedanput, osim vrha koji je početni i krajnji vrh ciklusa. Graf koji sadrži Hamiltonov ciklus naziva se Hamiltonov graf. Graf može sadržavati više Hamiltonovih ciklusa i ponekad želimo naći najkraći – taj se problem naziva problem trgovačkog putnika.

Dakle, da bi graf uopće imao rješenje problema trgovačkog putnika, mora imati barem jedan Hamiltonov ciklus, odnosno mora biti Hamiltonov graf.

U potpunim grafovima s  $n$  vrhova broj Hamiltonovih ciklusa je  $(n-1)!$  (u neusmjerenim grafovima  $(n-1)/2$ , s obzirom da su po dvije rute identične samo inverzne) te raste eksponencijalno s brojem vrhova.

Za pronalaženje rješenja problema potrebna je odgovarajuća metoda odnosno algoritam, koji se po načinu pronalaska rješenja dijele na [18]:

- Egzaktne metode
- Heurističke algoritme

### ***6.1.1. Egzaktne metode rješenja problema trgovačkog putnika***

Egzaktne metode garantiraju optimalno rješenje, ali su ograničene u praktičnoj primjeni na probleme s manjim brojem vrhova zbog kompleksnosti samog problema.

TSP spada u takozvane NP – teške probleme, kod kojih vrijeme računanja potrebno za rješenje raste eksponencijalno s veličinom problema.

Upravo zbog toga je često poželjno problem riješiti nekom aproksimativnom metodom koja će biti dovoljno brza i zadovoljavajuće točnosti za svrhu rješavanja. Danas se koriste i razvijaju različiti konstrukcijski heuristički algoritmi za generiranje nekog rješenja i algoritmi lokalnog pretraživanja za poboljšanje inicijalno generiranih rješenja.

Sve te metode baziraju se na određenom uvidu u problem i te moderne metode mogu pronaći rješenja i za ekstremno velike probleme (milijune gradova) u razumnom vremenu, koja su s visokom vjerojatnošću samo par postotaka od optimalnog rješenja.

### 6.1.2. Heuristički algoritmi problema trgovačkog putnika

Heuristički algoritmi za rješavanje problema trgovačkog putnika su konstruktivni algoritmi koji nastoje relativno jednostavno i brzo pronaći rješenje koje je dovoljno dobro. Pri tome se kvaliteta heurističkih algoritama procjenjuje na temelju usporedbe s poznatim optimalnim rješenjima dobivenim egzaktnim metodama.

Pogodni su za rješavanje i vrlo velikih problema. U osnovi, izgradnja rute temelji se na proceduri dodavanja vrha u svakom koraku.

U nastavku će se pojasniti najpoznatiji heuristički algoritmi.


#### 6.1.2.1. Algoritam najbližeg susjeda

Algoritam najbližeg susjeda (eng. nearest neighbour algorithm) je heuristički algoritam za generiranje TSP rješenja koji se temelji na pohlepnom dodavanju najbližeg vrha već dodanim vrhovima u ruti.

Algoritam se može opisati na sljedeći način [18]:


- Korak 1: Odaberi vrh  $i$  za početni vrh
- Korak 2: Odredi iz nedodanih vrhova onaj koji je najbliži posljednjem dodanom vrhu i uključi ga u rutu.
- Korak 3: Ponavljaj korak 2 sve dok svi vrhovi nisu u ruti i tada spoji prvi i zadnji vrh.

Na slici je prikazan primjer TSP heurističke metode najbližeg susjeda.



Slika 24. Algoritam najbližeg susjeda

Kao početna točka uzima se vrh 0 (mogao se uzeti i bilo koji drugi vrh) te se u tablici traži najbliži vrh početnom vrhu 0. Najbliži vrh, vrhu 0 je vrh 2 čija je udaljenost 7. Nakon toga se traži najbliži vrh vrhu 2, a u ovom slučaju je to vrh 1. Postupak se ponavlja dok svi vrhovi nisu spojeni. Na sljedećoj slici je prikazano rješenje navedenog primjera.



Slika 25. Rješenje algoritma najbližeg susjeda

Dobivena ruta je 0,2,1,4,3,5,0 s ukupnom duljinom  $6+5+15+4+12+15=57$ .

Kompleksnost algoritma je  $O(n^2)$ , što znači da broj računanja ne raste za više od  $n^2$ .

Modificirana primjena ovog algoritma je razmatranje svih  $n$  vrhova kao početne točke, čime raste kompleksnost na  $O(n^3)$ , ali se općenito dobije bolje rješenje.

#### 6.1.2.2. Pohlepna heuristika


Pohlepna heuristika (eng. greedy heuristics) je ime za drugu vrstu algoritma problema trgovačkog putnika. Iako mnogi autori koriste naziv „pohlepan“ za algoritam najbližeg susjeda, pohlepna heuristika za TSP zapravo je ovaj algoritam.

Ovom heuristikom promatra se potpuni graf s  $n$  vrhova i bridovima duljine  $c_{ij}$  između svaka dva para vrhova  $i$  i  $j$ . Ruta trovačkog putnika u takvom je grafu Hamiltonov ciklus u kojem je stupanj svih vrhova 2.

Izgradnja rute je u koracima, dodavanjem bridova krenuvši od najmanjeg. Pritom se izostavlja brid koji je već u ruti, koji bi zatvorio Hamiltonov ciklus s manje od  $n$  vrhova ili bi stvorio vrh trećeg stupnja.

Na slici je dan primjer rješenja problema pomoću algoritma pohlepne heuristike.

Primjer je isti kao i prethodni, samo je riješen ovim algoritmom.



**Slika 26. Pohlepna heuristika**

Dobivena ruta je (0,2,1,5,4,3,0) ukupne duljine 45. Pohlepna heuristika je kompleksnosti  $O(n^2 \log n)$ , dakle nešto sporija od algoritma najbližeg susjeda, s nešto boljim rezultatima.


#### 6.1.2.3. Algoritam umetanja najbližeg

Algoritam umetanja najbližeg (eng. nearest insertion algorithm) je jedan od algoritama umetanja kod kojih se u trenutnu rutu umeće jedan od preostalih vrhova prema određenom kriteriju. U ovom slučaju to je najbliži vrh trenutnoj ruti.

Algoritam se može opisati na sljedeći način:

- Korak 1: Odaberi vrh  $i$  za početni vrh 0.
- Korak 2: Pronađi vrh  $k$  takav da je  $c_{0k}$  minimalno (vrh najbliži početnom) i formiraj trenutnu rutu (0,  $k$ , 0).
- Korak 3: Nađi vrh  $h$  koji nije u trenutnoj ruti, a najbliži je nekom čvoru u trenutnoj ruti (korak odabira vrha).
- Korak 4: nađi brid  $(i,j)$  u trenutnoj ruti koja minimizira  $c_{ih} + c_{hj} - c_{ij}$ . Umetni vrh  $h$  između  $i$  i  $j$  (korak umetanja vrha).
- Korak 5: Ponavljaj korak 3 sve dok svi vrhovi nisu u ruti.

Na sljedećoj slici dan je primjer. Primjer je isti kao prethodna 2, ali je riješen algoritmom umetanja najbližeg.



Slika 27. Algoritam umetanja najbližeg

Ruta (0,1,2,5,4,3,0), a ukupne duljine  $10+5+8+6+4+8=41$


#### 6.1.2.4. Algoritam umetanja najudaljenijeg

Algoritam umetanja najudaljenijeg (eng. farthest insertion algorithm) je također algoritam umetanja pri čemu je kriterij za odabir vrha koji se dodaje trenutnoj ruti najveća udaljenost od nekog vrha trenutne rute.

Algoritam je sljedeći:

- Korak 1: Odaberi vrh  $i$  za početni vrh 0
- Korak 2: Pronađi vrh  $k$  takav da je  $c_{0k}$  maksimalno (vrh najdalji početnom) i formiraj trenutnu rutu  $(0,k,0)$ .
- Korak 3: Nađi vrh  $h$  koji nije u trenutnoj ruti, a najudaljeniji je od nekog čvora u trenutnoj ruti (korak odabira vrha).
- Korak 4: Nađi brid  $(i,j)$  u trenutnoj ruti koja minimizira  $c_{ih}+c_{hj}-c_{ij}$ . Umetni vrh  $h$  između  $i$  i  $j$  (korak umetanja vrha).
- Korak 5: Ponavljaj korak 3 sve dok svi vrhovi nisu u ruti.

Na slici je dano rješenje algoritma.



**Slika 28. Algoritam umetanja najudaljenijeg**

U koracima trenutne rute su drugačije, a konačno rješenje je u ovom primjeru ispalo kao i s prethodnim algoritmom, dakle ruta (0,1,2,5,4,3,0) duljine 41.

Algoritam umetanja najudaljenijeg općenito je bolji algoritam od prethodnih jer preferira segmente ruta koje predstavljaju najudaljenije korisnike, dok algoritmi najbližeg susjeda i umetanja najbližeg zbog svoje karakteristike "pohlepnih" algoritama u svakom koraku teže minimalnom povećanju troška, što u konačnici ne rezultira maksimalnom uštedom.

Kompleksnost ovog algoritma također je  $O(n^2)$ .

#### 6.1.2.5. Algoritam umetanja najjeftinijeg

Algoritam umetanja najjeftinijeg (eng. cheapest insertion algorithm) je algoritam sličan algoritmu umetanja najbližeg, jedino što se za umetanje ne odabire vrh koji je najbliži nekom već dodanom, već onaj za koji je trošak umetanja minimalan.

Koraci su sljedeći:

- Korak 1: Počni s vrhom 0 kao početkom rute
- Korak 2: Pronađi vrh  $k$  takav da je  $c_{0k}$  minimalno (vrh najbliži početnom) i formiraj trenutnu rutu (0,k,0).
- Korak 3: Nađi brid  $(i,j)$  u trenutnoj ruti takav da je  $c_{ih}+c_{hj}-c_{ij}$  minimalno. Umetni vrh  $h$  između  $i$  i  $j$  (korak umetanja vrha).
- Korak 4: Ponavljaj korak 3 sve dok svi vrhovi nisu u ruti.

Kompleksnost ovog algoritma je  $O(n^2 \log n)$ .



#### 6.1.2.6. *Clarke i Wright algoritam ušteda*

Clarke i Wright algoritam ušteda (eng. savings algorithm) heuristički je algoritam generiranja rute putujućeg trgovca koji se temelji na općenitijem algoritmu ušteda Clarka i Wrighta za rješavanje problema usmjeravanja vozila (VRP). Inicijalno se generira  $n$  ruta od početnog vrha do svih vrhova, te se zatim dodaju prečaci na temelju maksimalnih ušteda.

#### 6.1.2.7. *Algoritam Christofidesa*

Christofidesa algoritam rezultira najboljim rješenjima od svih heuristika generiranja rute, ali potrebno vrijeme računanja je veće u usporedbi s ostalima, odnosno kompleksnost algoritama je  $O(n^3)$ .

Svi opisani algoritmi koriste se za generiranje rješenja problema trgovačkog putnika. Ovisno o algoritmu, rješenja su u prosjeku iznad optimalnih za 10 do 22 % [18]:

- Algoritam najbližeg susjeda – 22 % od optimalnog
- Algoritam umetanja najudaljenijeg – 14 % od optimalnog
- Pohlepna heuristika - 12 % od optimalnog
- Algoritam ušteda – 12 % od optimalnog
- Christofidesov algoritam – 10 % od optimalnog.

U situacijama kada se želi bolje rješenje, na raspolaganju su, a i konstantno se razvijaju, metaheurističke metode za poboljšavanje inicijalnog rješenja. One se još nazivaju i heuristike lokalnog pretraživanja. Najpoznatije su: Pairwise interchange heuristika, K-OPT heuristike (2-OPT i 3-OPT su najpoznatije), Lin – Kernigham heuristika, Simulacijsko kaljenje, TABU pretraživanje, Genetički algoritmi, Kolonija mrava...

Metaheurističke metode se neće obrađivati u ovom radu te se dalje neće spominjati.

## **7. Analiza primjene komisioniranja unutar visokoregalnog skladišta s vrlo uskim prolazima**

U praktičnom dijelu ovoga rada prikazat će se usporedbe trajanja vremena vožnje u 4 slučaja. Prvi slučaj je posjećivanje lokacija tako da viličar najprije posjeti lokaciju koja je sljedeća po redu po  $x$  osi.

Drugi slučaj je komisioniranje po principu band heuristike tako da je regal podijeljen na 2 trake te se prvo vrši komisioniranje po gornjoj traci i to tako da se najprije posjete sve lokacije čija je vrijednost koordinate osi  $x$  najmanja pa prema najvećoj i nakon toga se vrši komisioniranje u donjoj traci od najveće vrijednosti koordinate osi  $x$  prema najmanjoj. Treći slučaj je komisioniranje primjenom heuristike problema trgovačkog putnika po algoritmu najbližeg susjeda, dok je četvrti slučaj također komisioniranje primjenom algoritma najbližeg susjeda, ali je skladište podijeljeno na 2 trake te se najprije vrši komisioniranje po algoritmu najbližeg susjeda u gornjoj traci te zatim u donjoj.

U sva četiri slučaja, nakon što viličar posjeti sve lokacije, vraća se u početnu točku.

Potrebno je izračunati vrijeme vožnje za svaki od pojedinih slučajeva tj. vrijeme potrebno viličaru da obiđe sve nasumično odabrane lokacije te se vrati u početnu točku, a to će se učiniti na nekoliko primjera. Najprije je potrebno slučajnim odabirom generirati lokacije koje viličar mora posjetiti. Na istim slučajno odabranim lokacijama izračunat će se vrijeme potrebno za obilazak svih lokacija za sva četiri primjera.

Da bi izračunati podaci bili relevantni, ispitivanje je potrebno provesti na dovoljno velikom broju uzoraka te će se ispitivanje ponoviti 10 000 puta i svaki će puta biti generirane različite slučajne lokacije koje viličar mora posjetiti.

Budući da je potrebna velika količina utrošenog vremena da bi se izračunalo vrijeme posjećivanja različitih slučajnih lokacija na 10 000 primjera, napravljen je program kojim će se brže doći do rezultata.

Program je napravljen u Java programskom jeziku te će se unaprijed odrediti ograničenja.

Najprije je potrebno odrediti brzine kretanja viličara.

Odabran je viličar proizvođača Jungheinrich, vodećeg svjetskog proizvođača viličara i skladišne tehnologije.


Viličar Jungheinrich EKX 513 može se kretati 2,5 m/s u smjeru osi  $x$  te 0,42 m/s u smjeru osi  $y$  tj brzina u smjeru  $y$ ,  $v_y$  je brzina dizanja i spuštanja.

Dakle, prva karakteristika koja je određena je brzina kretanja viličara, a ona je određena iz kataloga samog viličara:

$$v_x = 2,5 \text{ m/s}$$

$$v_y = 0,42 \text{ m/s}$$

Na sljedećoj slici prikazan je nacrt i tlocrt navedenog viličara.



**Slika 29. Nacrt viličara Jungheinrich EKX 513**

U tablici su prikazane brzine kretanja navedenog viličara te ostale karakteristike viličara.

**Tablica 2. Karakteristike viličara Jungheinrich EKX 513**

Characteristics	1.1	Manufacturer			Jungheinrich	
	1.2	Model			EKX 513	
	1.3	Drive			electric	
	1.4	Type of operation			order picker / turret truck	
	1.5	Load capacity / rated load	Q	lbs    kg	2,750	1,240
	1.6	Load center distance	c	in    mm	24.0	610
	1.8	Load distance, center of drive axle to fork	x	in    mm	17.3	440
Weights	1.9	Wheelbase	y	in    mm	71.9	1,826
	1.10	Center drive wheel / counterweight	z	in    mm	11.0	280
	2.1	Service weight including battery (see line 6.5)		lbs    kg	13,999	6,350
	2.2	Axle loading – loaded, drive / load		lbs    kg	12,610 / 4,145	5,720 / 1,880
	2.3	Axle loading – unloaded, drive / load		lbs    kg	8,488 / 5,512	3,850 / 2,500
	3.1	Tires			Vulkollan®	
	3.2	Tire size, drive		in    mm	15.0 x 7.6	380 x 192
Wheels, Chassis	3.3	Tire size, load		in    mm	15.7 x 6.3	400 x 160
	3.5	Wheels – number, drive / load (x = driven wheels)			2 / 1x	
	3.6	Track width, drive side		in    mm	57.1	1,208
	4.2	Collapsed mast height	h <sub>1</sub>	in    mm	117	2,955
	4.4	Maximum fork height (MFH)	h <sub>3</sub>	in    mm	137	3,500
	4.5	Overall extended height (OAE)	h <sub>4</sub>	in    mm	239	6,050
	4.7	Overhead guard height	h <sub>6</sub>	in    mm	101	2,550
	4.8	Seat height / platform height	h <sub>7</sub>	in    mm	16.9	430
	4.11	Auxiliary lift	h <sub>9</sub>	in    mm	70	1,780
	4.14	Maximum platform height	h <sub>12</sub>	in    mm	154	3,930
	4.19	Overall length	l <sub>1</sub>	in    mm	128.0	3,250
	4.20	Length to fork face, headlength	l <sub>2</sub>	in    mm	124.6	3,164
	4.21	Overall width	b <sub>1</sub> / b <sub>2</sub>	in    mm	47.6 / 57.9	1,210 / 1,400
	4.22	Fork dimensions, thick / width	s / e / l	in    mm	1.57 x 4.7 x 47.2	40 x 120 x 1,200
	4.23	Fork carriage ISO 2328, class / type A,B			2 / B	
	4.24	Fork carriage width	b <sub>3</sub>	in    mm	18.9	480
	4.25	Overall fork width	b <sub>5</sub>	in    mm	18.3	465
	4.27	Width across guide rollers	b <sub>6</sub>	in    mm	60	1,500
	4.29	Insert dimension	b <sub>7</sub>	in    mm	52.7	1,300
	4.30	Insert dimension from vehicle centerline	b <sub>8</sub>	in    mm	19.5	480
	4.31	Ground clearance, under mast (loaded)	m <sub>1</sub>	in    mm	3.1	80
	4.32	Ground clearance, center of wheelbase	m <sub>2</sub>	in    mm	3.1	80
	4.33	Aisle width (for 48 x 40 pallets (L x W))	Ast	in    mm	65.5 <sup>a</sup>	1,660 <sup>a</sup>
	4.35	Turning radius	Wa	in    mm	82.9	2,106
	4.38	Distance to swivel-forks' pivot point	l <sub>8</sub>	in    mm	35.6	904
	4.39	Total lift	h <sub>3</sub> +h <sub>9</sub>	in    mm	207	5,280
	4.40	Order picking height	h <sub>12</sub> +63.0	in    mm	217	5,530
	4.41	Distance: swivel-forks' pivot point to steering (traverse) rack	l <sub>6</sub> -x	in    mm	18.3	464
	4.42	Pallet width	b <sub>12</sub>	in    mm	40	1,016
	4.43	Pallet length	l <sub>6</sub>	in    mm	48	1,219
	4.44	Operator compartment entry width		in    mm	16.5	420
	4.45	Operator compartment clear height		in    mm	82.7	2,100
	4.46	Operator compartment outside width	b <sub>2</sub>	in    mm	56.7	1,440
	4.47	Width traverse motor housing	b <sub>14</sub>	in    mm	56.7	1,440
	4.48	Width extension arm	l <sub>10</sub>	in    mm	6.8	172
	4.49	Distance – swivel-forks' pivot point to fork face	r	in    mm	6.1	154
Performance	5.1	Travel speed, loaded / unloaded (rail guided)		mph    kph	5.6 <sup>a</sup> / 5.6 <sup>a</sup>	9 <sup>a</sup> / 9 <sup>a</sup>
	5.2	Lift speed, loaded / unloaded		ft/min    m / s	82.7 / 82.7 <sup>a</sup>	0.42 / 0.42 <sup>a</sup>
	5.3	Lowering speed, loaded / unloaded		ft/min    m / s	88.6 / 88.6	0.45 / 0.45
	5.4	Reach speed, loaded / unloaded		ft/min    m / s	49.2 / 49.2 <sup>a</sup>	0.25 / 0.25 <sup>a</sup>
	5.10	Service brake			reverse current / regenerative	
	5.11	Parking brake			electric spring loaded / laminated	



**Slika 30. Jungheinrich EKX 513**

Nakon što su određene brzine kretanja viličara potrebno je odrediti veličinu lokacije. Radi lakšeg računanja, dimenzije lokacija su fiksne i iznose  $1 \times 1$  m.

Napravit će se testiranje na različitim veličinama regala. Određeno je da je visina regala u svim slučajevima 10 m, a duljine se mijenjaju. Duljine regala će biti 25, 50 i 75 m tako da će se ispitivanje vršiti na regalima dimenzija  $10 \times 25$  m,  $10 \times 50$  m i  $10 \times 75$  m.

Na kraju je potrebno odrediti veličinu same narudžbe tj. broj lokacija koje će viličar posjetiti u jednom ciklusu. Kako je potrebno napraviti više ispitivanja kako bi se dobili optimalni rezultati, ispitivanje će se vršiti na različitim veličinama regala na više veličina narudžbe.

Prvo će se vršiti ispitivanje na 10 lokacija, zatim na 25 te na 75.

Iz svega navedenog vidi se da će biti 9 slučajeva na kojima će se ispitivati vrijeme koje je potrebno da viličar obiđe sve lokacije i vrati se u početnu poziciju.

Broj lokacija tj. veličina narudžbe označit će se sa 'X', visina regala slovom 'a', a duljina slovom 'b'.

U nastavku je navedeno svih 9 slučajeva:

1.  $X=10$ ,  $a=10$  m,  $b=25$  m,
2.  $X=10$ ,  $a=10$  m,  $b=50$  m,
3.  $X=10$ ,  $a=10$  m,  $b=75$  m,
4.  $X=25$ ,  $a=10$  m,  $b=25$  m,
5.  $X=25$ ,  $a=10$  m,  $b=50$  m,
6.  $X=25$ ,  $a=10$  m,  $b=75$  m,
7.  $X=50$ ,  $a=10$  m,  $b=25$  m,
8.  $X=50$ ,  $a=10$  m,  $b=50$  m,
9.  $X=50$ ,  $a=10$  m,  $b=75$  m.

### 7.1. Izračun vremena kod simultanog kretanja

Na jednom primjeru slučajno odabranih točaka grafički će se prikazati raspored točaka u regalima, stvarno kretanje viličara tijekom komisioniranja te vremena potrebna za prikazano kretanje.

Kretanje viličara je simultano, uz istovremeno uključene brzine  $v_x$  i  $v_y$ .

Kretanje viličara prikazat će se na primjeru regala veličine  $10 \times 25$  m uz 10 slučajno odabranih lokacija.

U svim slučajevima početna i završna točka je u koordinati  $(-1,0)$ .


#### Slučaj 1) $X=10$ , $a=10$ m, $b=25$ m,

Najprije je potrebno odrediti 10 lokacija koje će biti dio jednog ciklusa U sljedećoj tablici prikazane su koordinate točaka.

**Tablica 3. Slučajno odabrane točke**

1,5	5,6	15,4	4,3	22,0	16,1	17,7	2,5	9,8	16,5
-----	-----	------	-----	------	------	------	-----	-----	------

Slika 31. na sljedećoj stranici pokazuje raspored 10 lokacija u regalu veličine  $10 \times 25$ .



**Slika 31. Prikaz slučajno odabranih lokacija**

U nastavku su izračunata vremena za 4 slučaja različitog kretanja viličara unutar samog regala:

- Klasično komisioniranje (po vrijednosti  $x$ )
- Band heuristika
- Problem trgovačkog putnika (TSP) – algoritam najbližeg susjeda
- Problem trgovačkog putnika (TSP)– algoritam najbližeg susjeda + band heuristika

Za svaki navedeni slučaj, ručno je izračunata udaljenost svake točke te vrijeme koje potrebno viličaru do sljedeće lokacije.


a) Klasično komisioniranje (po vrijednosti  $x$ )

Prvi slučaj je klasično komisioniranje u kojoj viličar ide od početne lokacije do prve sljedeće lokacije čija je vrijednost koordinate  $x$  najmanja te se na kraju vraća u početnu lokaciju čija je koordinata  $(-1,0)$ . U sljedećoj tablici dan je raspored posjećivanja lokacija.

**Tablica 4. Raspored lokacija kod klasičnog komisioniranja**

1,5	2,5	4,3	5,6	9,8	15,4	16,1	16,5	17,7	22,0
-----	-----	-----	-----	-----	------	------	------	------	------

Na slici 32. prikazano je stvarno kretanje viličara od početne lokacije do svake pojedine lokacije te natrag u početnu. Crtkana linija označava kretanje od početne lokacije (-1,0) do prve posjećene lokacije te od zadnje posjećene lokacije do početne lokacije (-1,0).



Slika 32. Prikaz kretanja kod klasičnog komisioniranja

Kada se kreće iz lokacije (15,4) najprije ide na lokaciju (16,1), a zatim na (16,5) jer je potrebno posjetiti sve lokacije na toj koordinati  $x$ .

### Izračun vremena

U nastavku je napravljen izračun vremena od točke (-1,0) do (1,5).

(-1,0);(1,5)

$$t = \max\left(\frac{x_2 - x_1}{v_x}; \frac{y_2 - y_1}{v_y}\right) = \left(\frac{1 - (-1)}{2,5}; \frac{5 - 0}{0,42}\right) = (0,8; 11,9) = 11,9 \text{ s}$$

$$t_{1x} = \frac{x_2 - x_1}{v_x} = \frac{1 - (-1)}{2,5} = 0,8 \text{ s} - \text{vrijeme kretanja s obje brzine istovremeno}$$

$$t_{1y} = \frac{y_2 - y_1}{v_y} = \frac{5 - 0}{0,42} = 11,9 \text{ s} - \text{vrijeme kretanja s uključenom brzinom } v_y$$

$s_{1y} = t_{1x} \times v_y = 0,8 \times 0,42 = 0,336 \text{ m}$  - put prijeđen po  $y$  osi za vrijeme kretanja s obje brzine istovremeno

$s_{2y} = (y_2 - y_1) - s_{1y} = 5 - 0,336 = 4,664 \text{ m}$  - preostali put za prijeći s brzinom  $v_y$



$$t_{2y} = \frac{s_{2y}}{v_y} = \frac{4,664}{0,42} = 11,105 \text{ s}$$

$$t_{1UKUPNO} = t_{1x} + t_{2y} = 0,8 + 11,105 = 11,9 \text{ s}$$

---

$s_{1x}$  – put prijeđen po osi  $x$  za vrijeme kretanja obje brzine;  $s_{1x} = t_{1y} \times v_x$

$s_{2x}$  – put prijeđen po osi  $x$  s brzinom  $v_x$ ;  $s_x = t_{1x} \times v_x$

Radi preglednosti sadržaj, svi rezultati stavljeni su u tablicu u kojoj zadnji stupac označava vrijeme potrebno od jedne lokacije do druge. Ukupno vrijeme potrebno viličaru u ovom slučaju je 85,78 s.

Vrijeme i udaljenost su računati sa gore napisanim formulama za sve slučajeve.

**Tablica 5. Izračun vremena kod primjene klasičnog komisioniranja**

	Tpoč	Tzav	$t_x$ , [s]	$t_y$ , [s]	$s_{1y}$ , m	$s_{2y}$ ,m	$s_{1x}$ , m	$s_{2x}$ ,m	$t_{ukupno}$ [s]
<b>1</b>	(-1,0)	(1,5)	0,8	<b>11,9</b>	0,336	4,664	-	-	11,9
<b>2</b>	(1,5)	(2,5)	<b>0,4</b>	0	-	-	-	1	0,4
<b>3</b>	(2,5)	(4,3)	0,8	<b>4,76</b>	0,336	1,664	-	-	4,76
<b>4</b>	(4,3)	(5,6)	0,4	<b>7,143</b>	0,168	2,832	-	-	7,143
<b>5</b>	(5,6)	(9,8)	1,6	<b>4,76</b>	0,672	1,328	-	-	4,76
<b>6</b>	(9,8)	(15,4)	2,4	<b>9,52</b>	1,008	2,992	-	-	9,52
<b>7</b>	(15,4)	(16,1)	0,4	<b>7,143</b>	0,168	2,832	-	-	7,143
<b>8</b>	(16,1)	(16,5)	0	<b>9,52</b>	-	4	-	-	9,52
<b>9</b>	(16,5)	(17,7)	0,4	<b>4,76</b>	0,168	1,832	-	-	4,76
<b>10</b>	(17,7)	(22,0)	2	<b>16,67</b>	0,84	6,16	-	-	16,67
<b>11</b>	(22,0)	(-1,0)	<b>9,2</b>	0	-	-	-	23	9,2

$$\sum = 85,78 \text{ s}$$

Viličar uvijek ide na lokaciju čija je vrijednost koordinate  $x$  manja premda bi u većini slučajeva isplativije bilo posjetiti lokaciju koja mu je bliže s obzirom na udaljenost u smjeru  $y$ .

### b) Band heuristika


U slučaju komisioniranja primjenom band heuristike, viličar najprije obilazi sve lokacije čija je vrijednost koordinate  $y \geq 5$  te redom po  $x$  osi. Kada posjeti sve lokacije čija je vrijednost  $y \geq 5$ , posjećuje lokacije čija je vrijednosti  $y < 5$  te od najveće vrijednosti  $x$  prema najmanjoj.

U tablici je dan raspored točaka koje je viličar redom posjetio.

**Tablica 6. Raspored lokacija kod primjene band heuristike**

<b>1,5</b>	<b>2,5</b>	<b>5,6</b>	<b>9,8</b>	<b>16,5</b>	<b>17,7</b>	<b>22,0</b>	<b>16,1</b>	<b>15,4</b>	<b>4,3</b>
------------	------------	------------	------------	-------------	-------------	-------------	-------------	-------------	------------

Na slici je kao i u prethodnom slučaju, prikazano stvarno kretanje viličara te crtkane linije predstavljaju kretanje od i do početne odnosno završne točke.



### Slika 33. Prikaz kretanja primjenom band heuristike

Tablica prikazuje izračun vremena od početka do kraja te je ukupno vrijeme potrebno viličaru da obiđe sve lokacije te se vrati na početnu 69,1 s što je očekivano manje nego u slučaju kada viličar skuplja sve redom po osi  $x$ .

**Tablica 7. Izračun vremena primjenom band heuristike**

	Tpoč	Tzav	$t_x$ , [s]	$t_y$ , [s]	$s_{1y}$ , m	$s_{2y}$ , m	$s_{1x}$ , m	$s_{2x}$ , m	$t_{ukupno}$ [s]
<b>1</b>	(-1,0)	(1,5)	0,8	<b>11,9</b>	0,336	4,664	-	-	11,9
<b>2</b>	(1,5)	(2,5)	<b>0,4</b>	0	-	-	-	1	0,4
<b>3</b>	(2,5)	(5,6)	1,2	<b>2,38</b>	0,504	0,496	-	-	2,38
<b>4</b>	(5,6)	(9,8)	1,6	<b>4,76</b>	0,672	1,328	-	-	4,76
<b>5</b>	(9,8)	(16,5)	2,8	<b>7,143</b>	1,176	1,824	-	-	7,143
<b>6</b>	(16,5)	(17,7)	0,4	<b>4,76</b>	0,168	1,832	-	-	4,76
<b>7</b>	(17,7)	(22,0)	2	<b>16,67</b>	0,84	6,16	-	-	16,67
<b>8</b>	(22,0)	(16,1)	<b>2,4</b>	2,38			5,95	0,05	2,4
<b>9</b>	(16,1)	(15,4)	0,4	<b>7,143</b>	0,168	2,832	-	-	7,143
<b>10</b>	(15,4)	(4,3)	<b>4,4</b>	2,38	-	-	5,95	5,05	4,4
<b>11</b>	(4,3)	(-1,0)	2	<b>7,143</b>	0,84	2,16	-	-	7,143

$$\sum = 69,1 \text{ s}$$

c) Problem trgovačkog putnika (TSP) – algoritam najbližeg susjeda

**Tablica 8. Raspored lokacija kod primjene heuristike problema trgovačkog putnika**


<b>16,1</b>	<b>22,0</b>	<b>4,3</b>	<b>15,4</b>	<b>16,5</b>	<b>5,6</b>	<b>1,5</b>	<b>2,5</b>	<b>17,7</b>	<b>9,8</b>
-------------	-------------	------------	-------------	-------------	------------	------------	------------	-------------	------------

Kao i u prethodna 2 slučaja, u tablici je prikazan raspored točaka koje se redom posjećuju.

Dakle, primjenom algoritma najbližeg susjeda, viličar odlazi na lokaciju koja mu vremenski najbliža te se nakon što obiđe sve lokacije vraća u početnu točku.

Viličar iz točke (-1,0) ide u točku (16,1). Premda se to na slici ne čini kao najbliža lokacija, u tablici u kojoj su izračunata sva vremena vidljivo je da je to uistinu tako. Razlog tome je što se viličar skoro 6 puta brže kreće s uključenom brzinom  $v_x$  u odnosu na brzinu  $v_y$ .

Na slici 34. je prikazano kretanje viličara.



Slika 34. Prikaz kretanja primjenom heuristike problema trgovačkog putnika

U tablici su izračunata vremena kretanja između pojedinih lokacija i udaljenosti.

Tablica 9. Izračun vremena primjenom algoritma najbližeg susjeda

	Tpoč	Tzav	$t_x$ , [s]	$t_y$ , [s]	$s_{1y}$ , m	$s_{2y}$ , m	$s_{1x}$ , m	$s_{2x}$ , m	$t_{ukupno}$ [s]
<b>1</b>	(-1,0)	(16,1)	<b>6,8</b>	2,38	-	-	5,95	11,05	6,8
<b>2</b>	(16,1)	(22,0)	<b>2,4</b>	2,38	-	-	5,95	0,05	2,4
<b>3</b>	(22,0)	(4,3)	<b>7,2</b>	7,143	-	-	17,86	0,14	7,2
<b>4</b>	(4,3)	(15,4)	<b>4,4</b>	2,38	-	-	5,95	5,05	4,4
<b>5</b>	(15,4)	(16,5)	0,4	<b>2,38</b>	0,168	0,832	-	-	2,38
<b>6</b>	(16,5)	(5,6)	<b>4,4</b>	2,38	-	-	5,95	5,05	4,4
<b>7</b>	(5,6)	(1,5)	1,6	<b>2,38</b>	0,672	0,328	-	-	2,38
<b>8</b>	(1,5)	(2,5)	<b>0,4</b>	0	-	-	-	1	0,4
<b>9</b>	(2,5)	(17,7)	<b>6</b>	4,76	-	-	11,9	3,1	6
<b>10</b>	(17,7)	(9,8)	<b>3,2</b>	2,38	-	-	5,95	2,05	3,2
<b>11</b>	(9,8)	(-1,0)	4	<b>19,05</b>	1,68	6,32	-	-	19,05

$$\sum = 58,61 \text{ s}$$

U ovom slučaju viličaru je potrebno 58,61 s da napravi jedan ciklus što je najbolji rezultat do sada.


d) Problem trgovačkog putnika – algoritam najbližeg susjeda + band heuristika

U slučaju primjene algoritma najbližeg susjeda kombiniranog sa band heuristikom, viličar najprije obilazi sve vremenski najbliže lokacije prethodno posjećenoj lokaciji čije su vrijednosti koordinate  $y \geq 5$  i nakon toga sve vremenski najbliže lokacije prethodno posjećenoj lokaciji čije su vrijednosti koordinate  $y < 5$ .

**Tablica 10. Raspored lokacija kod primjene heuristike problema trgovačkog putnika i band heuristike**

1,5	2,5	5,6	16,5	17,7	9,8	15,4	4,3	16,1	22,0
-----	-----	-----	------	------	-----	------	-----	------	------

Niže je prikazana slika kretanja viličara. Plavom linijom označeno je kretanje između lokacija, crtkanom plavom linijom, kretanje od početne točke do prve lokacije te od zadnje lokacije do početne.



**Slika 35. Prikaz kretanja primjenom heuristike problema trgovačkog putnika i band heuristike**

U ovom slučaju viličaru je trebalo 57,37 s za cijeli ciklus što je za 1,24 s manje nego u slučaju primjene algoritma najbližeg susjeda bez primjene band heuristike. Razlika je mala, ali da bi se moglo utvrditi da je to stvarno tako potrebno je napraviti ispitivanje na više uzoraka.

**Tablica 11. Izračun vremena primjenom algoritma najbližeg susjeda i band heuristike**

	Tpoč	Tzav	$t_x$ , [s]	$t_y$ , [s]	$s_{1y}$ , m	$s_{2y}$ , m	$s_{1x}$ , m	$s_{2x}$ , m	$t_{ukupno}$ [s]
<b>1</b>	(-1,0)	(1,5)	0,8	<b>11,9</b>	0,336	4,664	-	-	11,9
<b>2</b>	(1,5)	(2,5)	<b>0,4</b>	0	-	-	-	1	0,4
<b>3</b>	(2,5)	(5,6)	1,2	<b>2,38</b>	0,504	0,496	-	-	2,38
<b>4</b>	(5,6)	(16,5)	<b>4,4</b>	2,38	-	-	5,95	5,05	4,4
<b>5</b>	(16,5)	(17,7)	0,4	<b>4,76</b>	0,168	1,832	-	-	4,76
<b>6</b>	(17,7)	(9,8)	<b>3,2</b>	2,38	-	-	5,95	2,05	3,2
<b>7</b>	(9,8)	(15,4)	2,4	<b>9,52</b>	1,008	2,992	-	-	9,52
<b>8</b>	(15,4)	(4,3)	<b>4,4</b>	2,38	-	-	5,95	5,05	4,4
<b>9</b>	(4,3)	(16,1)	<b>4,8</b>	4,76	-	-	11,9	0,1	4,8
<b>10</b>	(16,1)	(22,0)	<b>2,4</b>	2,38	-	-	5,95	0,05	2,4
<b>11</b>	(22,0)	(-1,0)	<b>9,2</b>	0	-	-	-	23	9,2

$$\sum = 57,37 \text{ s}$$

Točke su slučajno odabrane u programu Eclipse te je navedeni program uz uvjete prikazane na slici dobio identične rezultate.

Prvi red prikazuje broj točaka koje će se generirati, drugi red visinu skladišta koja je u ovom slučaju 10 m, treći red prikazuje duljinu skladišta, dok četvrti prikazuje broj ponavljanja testova što je u ovom slučaju 1. Ispod toga su zadane brzine viličara.

```

int maksimalniBrojRandomTocakaZaTestiranje=10; //maksimalni broj tocaka, koje cemo koristiti u testiranju
int maksimalnaDuljinaPoOsiY=9; //maksimalna duljina po osi Y +1
int maksimalnaDuljinaPoOsiX=24; //maksimalna duljina po osi X +1
int maksimalniBrojTestiranja=1; //maksimalni broj testova

double brzinaPoOsiX=2.5;
double brzinaPoOsiY=0.42;

```

**Slika 36. Prikaz uvjeta iz programa**

Iz rezultata prikazanih na sljedećoj slici, može se zaključiti da je najviše vremena potrebno za vožnju kod komisioniranja po osi  $x$ , a najmanje kada se posjećuje najbliža sljedeća lokacija, ali tako da najprije posjeti sve lokacije u gornjem dijelu regala te nakon toga u donjem. U zadnje 2 metode razlike su vrlo male te će se na napravljenih više testova dobiti točniji rezultati.

```
Prosjecno vrijeme prvog testa nakon 1 izvođenja je 85.7904761904762 sekundi
Prosjecno vrijeme drugog testa nakon 1 izvođenja je 69.10476190476192 sekundi
Prosjecno vrijeme trećeg testa nakon 1 izvođenja je 58.60952380952381 sekundi
Prosjecno vrijeme četvrtog testa nakon 1 izvođenja je 57.37142857142857 sekundi
```

**Slika 37. Prikaz rezultata dobivenih programom**

## 7.2. Izračun vremena kod rektilinearnog kretanja

Na istom primjeru izračunat će se vrijeme vožnje kada bi kretanje viličara bilo pravocrtno, odnosno kada ne bi bile uključene obje brzine istovremeno već prvo jedna u jednom smjeru pa druga tj. kada bi kretanje bilo rektilinearno.

U tom slučaju, tek kada se završi pravocrtno kretanje u jednom smjeru, uključuje se druga brzina i nastavlja se kretanje do lokacije.


### a) Klasično komisioniranje (po vrijednosti $x$ )

U tablici su prikazane koordinate lokacija po redoslijedu posjećivanja. Budući da je riječ o istom primjeru, redoslijed posjećivanja lokacija je identičan.

**Tablica 12. Raspored koordinata**

1,5	2,5	4,3	5,6	9,8	15,4	16,1	16,5	17,7	22,0
-----	-----	-----	-----	-----	------	------	------	------	------

Na slici je prikazano kretanje viličara od lokacije do lokacije. Kako su sva kretanja pravocrtna, tako je ukupno vrijeme potrebno za posjećivanje svake lokacije duže nego kada se viličar kreće sa istovremeno uključenim brzinama u smjeru  $x$  i  $y$  osi.



**Slika 38. Prikaz kretanja primjenom klasičnog komisioniranja kod rektilinearnog kretanja**

Ukupno vrijeme potrebno za obilazak svih lokacija računa se tako da se zbroji vrijeme potrebno za kretanje u smjeru osi  $x$  i vrijeme potrebno za kretanje u smjeru osi  $y$ .

U nastavku je napravljen izračun vremena od točke  $(-1,0)$  do  $(1,5)$ .

$$t = \sum \left( \frac{x_2 - x_1}{v_x}; \frac{y_2 - y_1}{v_y} \right) = \left( \frac{1 - (-1)}{2,5}; \frac{5 - 0}{0,42} \right) = (0,8; 11,9) = 12,7 \text{ s}$$

$$t_x = \frac{x_2 - x_1}{v_x} = \frac{1 - (-1)}{2,5} = 0,8 \text{ s} - \text{vrijeme kretanja s uključenom brzinom } v_x$$

$$t_y = \frac{y_2 - y_1}{v_y} = \frac{5 - 0}{0,42} = 11,9 \text{ s} - \text{vrijeme kretanja s uključenom brzinom } v_y$$

$$s_y = t_x \times v_y = 0,8 \times 0,42 = 0,336 \text{ m} - \text{put prijeđen po } y \text{ osi za vrijeme } s \text{ uključenom brzinom } v_y$$

$$s_x - \text{put prijeđen po osi } x \text{ za vrijeme kretanja s uključenom brzinom } v_x$$

U tablici su prikazana sva vremena i udaljenosti između lokacija. U stupcima  $t_x$  i  $t_y$  zapisano je vrijeme potrebno da se dođe do svake lokacije sa uključenom svakom brzinom posebno, a u zadnjem stupcu zapisano je vrijeme koje je zbroj stupaca  $t_x$  i  $t_y$  te predstavlja ukupno vrijeme potrebno od jedne koordinate do sljedeće. Na kraju je dobiveno ukupno vrijeme koje je u ovom slučaju 94,58 s.



**Tablica 13. Izračun vremena primjenom klasično komisioniranja**

	<b>Tpoč</b>	<b>Tzav</b>	$t_x, [s]$	$t_y, [s]$	$s_x, m$	$s_y, m$	$t_{ukupno} [s]$
<b>1</b>	(-1,0)	(1,5)	0,8	11,9	2	5	12,7
<b>2</b>	(1,5)	(2,5)	0,4	0	1	-	0,4
<b>3</b>	(2,5)	(4,3)	0,8	4,76	2	2	5,56
<b>4</b>	(4,3)	(5,6)	0,4	7,143	1	3	7,543
<b>5</b>	(5,6)	(9,8)	1,6	4,76	4	2	6,36
<b>6</b>	(9,8)	(15,4)	2,4	9,52	6	4	11,92
<b>7</b>	(15,4)	(16,1)	0,4	7,143	1	3	7,543
<b>8</b>	(16,1)	(16,5)	0	9,52	-	4	9,52
<b>9</b>	(16,5)	(17,7)	0,4	4,76	1	2	5,16
<b>10</b>	(17,7)	(22,0)	2	16,67	5	7	18,67
<b>11</b>	(22,0)	(-1,0)	9,2	0	23	-	9,2

$$\sum = 94,58 s$$

Iz tablice se vidi da je ukupno vrijeme duže u slučaju kada se viličar kreće rektilnearno jer je sa simultanim kretanjem potrebno 85,78 s da se posjete sve lokacije..

#### b) Band heuristika


Kao i kod klasičnog komisioniranja, put posjećivanja lokacija je jednak putu posjećivanja lokacija kada se viličar kreće sa uključene obje brzine.

U tablici su zapisane koordinate koje se redom posjećuju u slučaju primjene band heuristike.

**Tablica 14. Raspored koordinata**

<b>1,5</b>	<b>2,5</b>	<b>5,6</b>	<b>9,8</b>	<b>16,5</b>	<b>17,7</b>	<b>22,0</b>	<b>16,1</b>	<b>15,4</b>	<b>4,3</b>
------------	------------	------------	------------	-------------	-------------	-------------	-------------	-------------	------------

Na slici je prikazano kretanje viličara te je kao i u primjeru sa simultanim kretanjem crtkano označeno kretanje od i do početne odnosno završne točke.



### Slika 39. Prikaz kretanja primjenom band heuristike kod rektilinearnog kretanja

U tablici se vidi da je došlo do povećanja vremena. Kod ovakvog kretanja potrebno je 85,06 s što je znatno više nego kada se koriste obje brzine istovremeno.

**Tablica 15. Izračun vremena primjenom band heuristike**

	<b>Тпоч</b>	<b>Тзав</b>	$t_x$ , [s]	$t_y$ , [s]	$s_x$ ,m	$s_y$ , m	$t_{ukupno}$ [s]
<b>1</b>	(-1,0)	(1,5)	0,8	11,9	2	5	12,7
<b>2</b>	(1,5)	(2,5)	0,4	0	1	-	0,4
<b>3</b>	(2,5)	(5,6)	1,2	2,38	3	1	3,58
<b>4</b>	(5,6)	(9,8)	1,6	4,76	4	2	6,36
<b>5</b>	(9,8)	(16,5)	2,8	7,143	7	3	9,943
<b>6</b>	(16,5)	(17,7)	0,4	4,76	1	2	5,16
<b>7</b>	(17,7)	(22,0)	2	16,67	5	7	18,67
<b>8</b>	(22,0)	(16,1)	2,4	2,38	6	1	4,78
<b>9</b>	(16,1)	(15,4)	0,4	7,143	1	3	7,543
<b>10</b>	(15,4)	(4,3)	4,4	2,38	11	1	6,78
<b>11</b>	(4,3)	(-1,0)	2	7,143	5	3	9,143

$$\Sigma = 85,06 \text{ s}$$


## c) Problem trgovačkog putnika (TSP)– algoritam najbližeg susjeda

Kao i u prethodnim primjerima, raspored koordinata je ostao nepromijenjen te je zapisan u tablici.

**Tablica 16. Raspored koordinata**

16,1	22,0	4,3	15,4	16,5	5,6	1,5	2,5	17,7	9,8
------	------	-----	------	------	-----	-----	-----	------	-----

Na slici 40. jasno se vide kretanja viličara. Kod simultanog kretanja teško je uočiti da se najprije ide na lokaciju (16,1) pa na (22,0). U ovom primjeru kretanje viličara je horizontalno raspoređeno što ne mora biti slučaj kada bi raspored koordinata bio drugačiji.



**Slika 40. Prikaz kretanja primjenom algoritma najbližeg susjeda kod rektilinearnog kretanja**

U tablici je izračunato ukupno vrijeme potrebno za jedan ciklus. U ovom primjeru to je 88,41 s. Ako se to vrijeme usporedi s onim dobivenim kod simultanog kretanja koje iznosi 58,61 s, vidi se velika razlika od 29,81 s. Razlog tolikoj velikoj razlici je zbrajanje vremena koja su i u slučaju kretanja po osi  $x$  i u slučaju kretanja po osi  $y$  velika što se vidi i u tablici.

**Tablica 17. Izračun vremena primjenom heuristike problema trgovačkog putnika**

	<b>Tpoč</b>	<b>Tzav</b>	$t_x, [s]$	$t_y, [s]$	$s_x, m$	$s_y, m$	$t_{ukupno} [s]$
<b>1</b>	(-1,0)	(16,1)	6,8	2,38	17	1	9,18
<b>2</b>	(16,1)	(22,0)	2,4	2,38	6	1	4,78
<b>3</b>	(22,0)	(4,3)	7,2	7,143	18	3	14,343
<b>4</b>	(4,3)	(15,4)	4,4	2,38	11	1	6,78
<b>5</b>	(15,4)	(16,5)	0,4	2,38	1	1	2,78
<b>6</b>	(16,5)	(5,6)	4,4	2,38	11	1	6,78
<b>7</b>	(5,6)	(1,5)	1,6	2,38	4	1	3,98
<b>8</b>	(1,5)	(2,5)	0,4	0	1	-	0,4
<b>9</b>	(2,5)	(17,7)	6	4,76	15	2	10,76
<b>10</b>	(17,7)	(9,8)	3,2	2,38	8	1	5,58
<b>11</b>	(9,8)	(-1,0)	4	19,05	10	8	23,05

$$\sum = 88,41 s$$

d) Problem trgovačkog putnika (TSP) – algoritam najbližeg susjeda + band heuristika

Razlika u vremenu između c) i d) slučaja bila je vrlo mala kod simultanog kretanja.


Kod rektilinearnog kretanja razlika se povećala zbrajanjem vremena kretanja.

Koordinate su ostale iste, kao i u prethodnim slučajevima, i prikazani su u tablici.

**Tablica 18. Raspored koordinata**

<b>1,5</b>	<b>2,5</b>	<b>5,6</b>	<b>16,5</b>	<b>17,7</b>	<b>9,8</b>	<b>15,4</b>	<b>4,3</b>	<b>16,1</b>	<b>22,0</b>
------------	------------	------------	-------------	-------------	------------	-------------	------------	-------------	-------------

Na slici su prikazana kretanja između lokacija. Premda se čini da je lokacija (9,8) bliže lokaciji (5,6), to nije tako jer je lokacija (16,5) vremenski bliža.



**Slika 41. Prikaz kretanja primjenom algoritma najbližeg susjeda i band heuristike kod rektilinearnog kretanja**

Izračunom prikazanim u tablici, vidi se da je kod rektilinearnog kretanja još više do izražaja došlo vrijeme kretanja te je po ovom primjeru najbolji izbor primjena kombinacije problema trgovačkog putnika i band heuristike. Vrijeme potrebno za jedan ciklus je 79,46 što je u odnosu na sve ostale rezultate najbolje vrijeme.

**Tablica 19. Izračun vremena primjenom heuristike problema trgovačkog putnika i band heuristike**

	<b>Tpoč</b>	<b>Tzav</b>	$t_x, [s]$	$t_y, [s]$	$s_x, m$	$s_y, m$	$t_{ukupno} [s]$
<b>1</b>	(-1,0)	(1,5)	0,8	11,9	2	5	12,7
<b>2</b>	(1,5)	(2,5)	0,4	0	-	1	0,4
<b>3</b>	(2,5)	(5,6)	1,2	2,38	3	1	3,58
<b>4</b>	(5,6)	(16,5)	4,4	2,38	11	1	6,78
<b>5</b>	(16,5)	(17,7)	0,4	4,76	1	2	5,16
<b>6</b>	(17,7)	(9,8)	3,2	2,38	8	1	5,58
<b>7</b>	(9,8)	(15,4)	2,4	9,52	6	4	11,92
<b>8</b>	(15,4)	(4,3)	4,4	2,38	11	1	6,78
<b>9</b>	(4,3)	(16,1)	4,8	4,76	12	2	9,56
<b>10</b>	(16,1)	(22,0)	2,4	2,38	6	1	4,78
<b>11</b>	(22,0)	(-1,0)	9,2	0	23	-	9,2

$$\sum = 76,45 \text{ s}$$

Točnost programa i računanja u prethodna 2 poglavlja prikazana je na sljedećoj slici gdje se vidi da je program dobio identične rezultate.

```

Prosjecno vrijeme prvog testa nakon (zboj vremena po osima X i Y) 1 izvođenja je 94.59047619047621 sekundi
Prosjecno vrijeme drugog testa nakon (zboj vremena po osima X i Y) 1 izvođenja je 85.06666666666666 sekundi
Prosjecno vrijeme trećeg testa nakon (zboj vremena po osima X i Y) 1 izvođenja je 88.41904761904762 sekundi
Prosjecno vrijeme četvrtog testa nakon (zboj vremena po osima X i Y) 1 izvođenja je 76.45714285714286 sekundi

```

**Slika 42. Prikaz rezultata dobivenih programom**

Premda u ovom primjeru ispada da je najbolje koristiti kombinaciju problema trgovačkog putnika, to se mora provjeriti jer se zaključci ne mogu donositi na temelju jednog primjera.

## 8. Komentar rezultata analize

Testovi prikazani u poglavljima 7.1. i 7.2. izvedeni su 10 000 puta na više tipova regala.

U svim primjerima najbolje rezultate daje vožnja komisioniranjem po algoritmu najbližeg susjeda.

U sljedećem poglavlju napravljena je usporedba kretanja.

### 8.1. Usporedba simultanog i rektilinearnog kretanja

U nastavku je prikazana tablica sa rezultatima svih vrsta regala.

Plavom bojom su označeni rezultati simultanog, a zelenom rektilinearnog kretanja.

**Tablica 20. Usporedba rezultata na 10 000 uzoraka kod simultanog i rektilinearnog kretanja**

SIMULTANO	Klasično [s]		Band		TSP [s]		TSP + band [s]	
REKTILINEARNO			heuristika[s]					
1. x=10, a=10 m, b=25 m,	85,33	99,74	61,88	75,33	<u>50,95</u>	<u>69,27</u>	<u>52,35</u>	<u>70,69</u>
2. x=10, a=10 m, b=50 m,	92,85	117,54	<u>70,46</u>	<u>93,8</u>	<u>67,08</u>	<u>94,62</u>	70,86	98,56
3. x=10, a=10 m, b=75 m,	105,47	136,35	<u>82,44</u>	<u>112,34</u>	<u>84,41</u>	<u>118,39</u>	87,56	119,94
4. x=25, a=10 m, b=25 m,	187,62	203,35	112,29	126,83	<u>72,22</u>	<u>96,56</u>	<u>76,97</u>	<u>101,96</u>
5. x=25, a=10 m, b=50 m,	197,96	225,05	119,54	147,11	<u>98,69</u>	<u>138,32</u>	<u>105,73</u>	<u>144,58</u>
6. x=25, a=10 m, b=75 m,	210,23	245,18	<u>128,98</u>	<u>166,83</u>	<u>122,68</u>	<u>172,12</u>	131,37	178,72
7. x=50, a=10 m, b=25 m,	342,62	359,43	194,08	209,09	<u>96,65</u>	<u>125,47</u>	<u>101,06</u>	<u>128,71</u>
8. x=50, a=10 m, b=50 m,	368,84	397,54	202,9	232,64	<u>134,6</u>	<u>183,86</u>	<u>143,43</u>	<u>191,01</u>
9. x=50, a=10 m, b=75 m.	383,67	420,42	210,11	253,22	<u>166,54</u>	<u>230,73</u>	<u>178,69</u>	<u>240,196</u>

U tablici s rezultatima, podvučeno i podebljano vrijeme, je ono koje daje nabolje rezultate, a crtkano podvučeno je vrijeme koje daje druge po redu najbolje rezultate.

Kod simultanog kretanja, u svim slučajevima, osim u slučaju kada je duljina regala 75 m i veličina narudžbe 10, najbolje rezultate daje heuristika problema trgovačkog putnika preko algoritma najbližeg susjeda. U slučaju kada je duljina regala 75 m i veličina narudžbe 10, najbolje rezultate daje band heuristika.

Kod iste veličine narudžbe, povećanjem duljine regala, logično povećava se i vrijeme jednog ciklusa. Time se može zaključiti da se povećavanjem veličine regala, povećava i vrijeme vožnje komisioniranja. Međutim, kada se veličina narudžbe poveća s 10 na 25 ili sa 25 na 50, vrijeme jednog ciklusa je manje kod veće narudžbe ako se ispitivanje provodi na regalu veličine  $10 \times 25$  u usporedbi sa regalom veličine  $10 \times 75$ . Ako se uspoređi 3. i 4. slučaj te 6. i 7. slučaj, vidi se da vrijeme jednog ciklusa ovisi i o veličini regala i o veličini narudžbe. Kod regala duljine 75 m potrebno je više vremena da se posjete sve lokacije jer su one slučajnim odabirom udaljenije jedna od druge, nego kada se na manjem regalu treba posjetiti više lokacija.

U svim slučajevima najgori rezultati su zapisani u stupcu klasičnog komisioniranja po  $x$  osi što je logično jer se bez obzira na moguću blizinu neke lokacije ide na onu dalju ako je ona sljedeća po redu po osi  $x$ . Drugo najbolje vrijeme daje u većini slučajeva komisioniranje kombiniranjem TSP-a i band heuristike (rezultati zapisani u 7. stupcu).

Komisioniranje primjenom band heuristike ima bolje rezultate od kombinacije TSP-a i band heuristike u 2. i u 6. slučaju. U drugom slučaju, razlika je vrlo mala, gotovo zanemariva, s obzirom da je na 10 000 testova razlika 0,4 s. U 6. slučaju, razlika je nešto veća, ali je ovdje riječ o najvećem regalu  $10 \times 75$  m i 25 narudžbi pa se može zaključiti da su rezultati takvi jer se u slučaju sa kombinacijom TSP-a i band heuristike može dogoditi da se izostavi neka lokacija na gornjoj polovici regala sa koordinatom  $x$  male vrijednosti da bi se posjetila lokacija koja je vremenski manje udaljena, a dalje je u regalu (gledajući s obzirom na koordinatu  $x$ ). Budući da se u slučaju kada se kombinira TSP i band heuristika najprije moraju posjetiti sve lokacije koje su najbliže jedna drugoj u gornjoj polovici, može se dogoditi da se viličar s jednog kraja regala (veća vrijednost po osi  $x$ ) vraća na drugi kraj (manja vrijednost po osi  $x$ ) te se tu izgubi nešto vremena. Kada se spusti u donji dio regala (koordinata  $y < 5$ ) opet posjećuje vremenski najbliže lokacije. U 9. slučaju gdje je veličina regala isto  $10 \times 75$  m, ipak je bolja kombinacija TSP-a i band heuristike od slučaja u kojem se koristi samo band heuristika. Razlog tome je što se u 9. slučaju posjećuje 50 lokacija, dakle duplo više nego u 6. slučaju, pa se ne gubi toliko vremena na putovanje od jedne lokacije do druge jer se na istoj veličini regala treba posjetiti više lokacija.



Samo u 3. slučaju, gdje nabolje rezultate daje korištenje band heuristike, druge najbolje rezultate daje TSP korištenjem algoritma najbližeg susjeda.

Ako se ovih 9 slučajeva podjele na 3 veća slučaja gledajući s obzirom na veličinu narudžbe (u tablici crnom linijom odvojeno), može se zaključiti da se s povećanjem broja narudžbi ustaljuje najbolje vrijeme vožnje komisioniranja. U slučaju kada je veličina narudžbe 50, kod svih veličina regala najbolje vrijeme dobiva se korištenjem TSP-a, a drugo najbolje vrijeme kombinacijom TSP-a i band heuristike.

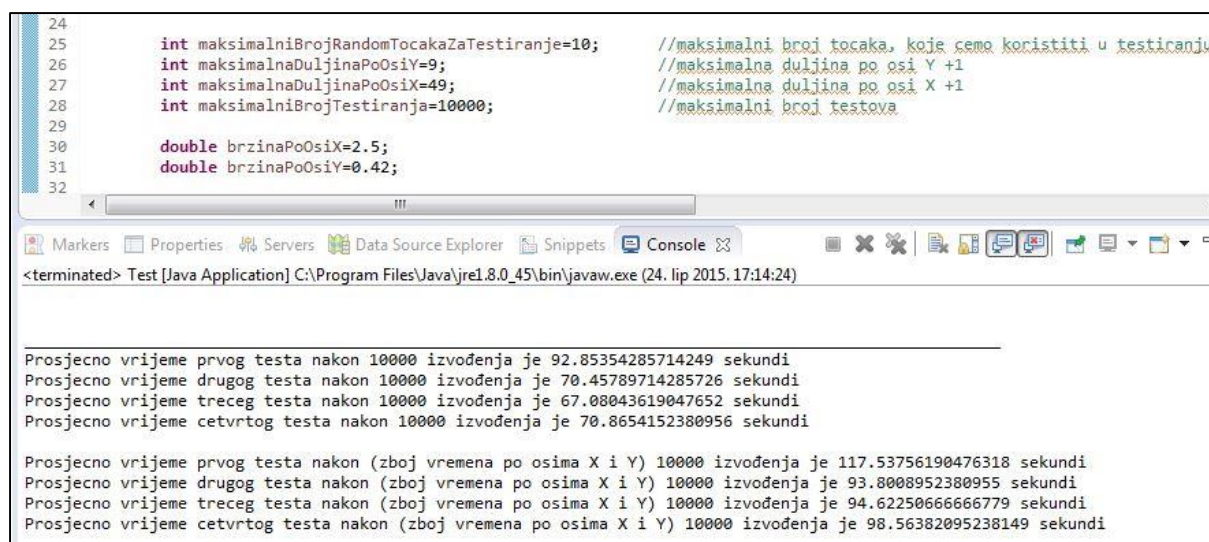
Kod rektilinearnog kretanja, u 3 slučaja najbolji rezultati dobiveni su korištenjem band heuristike, a u 6 slučajeva korištenjem TSP heuristike. U slučajevima gdje korištenje TSP-a daje najbolje rezultate, druge najbolje rezultate daje korištenje kombinacije TSP-a i band heuristike, a u slučajevima gdje korištenje band heuristike daje najbolje rezultate, druge najbolje rezultate daje korištenje TSP-a.

Budući da su kod ovakvog kretanja rezultati dobiveni zbrajanjem vremena potrebnih da se prođe udaljenost od jedne do druge lokacije po osi  $x$  i po osi  $y$ , za očekivati je da se najbolji rezultati neće u potpunosti poklapati sa rezultatima dobivenim simultanim kretanjem.

U slučajevima kada je veličina narudžbe 10, kod regala  $10 \times 50$  i  $10 \times 75$ , bolji su rezultati dobiveni korištenjem band heuristike nego korištenjem TSP-a. Razlog tome je što kod većih regala, a malih veličina narudžbe, postoji mogućnost da su slučajno odabrane lokacije jako udaljene jedna od druge pa je i po  $x$  i po  $y$  osi potrebno puno vremena da se dođe od jedne do druge lokacije ili se kod povratka iz zadnje posjećene lokacije u početnu točku izgubi dosta vremena. Kako se ovdje zbrajaju oba vremena, bolji su rezultati kod korištenja band heuristike. Kao i kod simultanog kretanja, vidi se da se povećavanjem broja narudžbi kod istih veličina regala, ustaljuju najbolji rezultati. Tako su kod veličine narudžbe 50 najbolji rezultati dobiveni korištenjem TSP-a, a drugi najbolji rezultati korištenjem kombinacije TSP-a i band heuristike. Isto kao kod simultanog kretanja, kada se usporede 3. i 4. slučaj te 6. i 7. slučaj, vremena vožnje komisioniranja su manja u slučajevima s većim brojem narudžbi, a manjim regalom nego kada je obrnuto.

Kao i kod simultanog kretanja, najgori rezultati su dobiveni korištenjem klasičnog komisioniranja po  $x$  osi.

Dokaz da su svi podaci u tablicama ispravni daje slika 43. na kojoj su prikazani rezultati za testiranje za 10 narudžbi u regalu  $10 \times 50$  na 10 000 uzoraka.



```

24
25     int maksimalniBrojRandomTocakaZaTestiranje=10;           //maksimalni broj tocaka, koje cemo koristiti u testiranju
26     int maksimalnaDuljinaPoOsiY=9;                          //maksimalna duljina po osi Y +1
27     int maksimalnaDuljinaPoOsiX=49;                         //maksimalna duljina po osi X +1
28     int maksimalniBrojTestiranja=10000;                     //maksimalni broj testova
29
30     double brzinaPoOsiX=2.5;
31     double brzinaPoOsiY=0.42;
32

```

Console Output:

```

<terminated> Test [Java Application] C:\Program Files\Java\jre1.8.0_45\bin\javaw.exe (24. lip 2015. 17:14:24)

Prosjecno vrijeme prvog testa nakon 10000 izvođenja je 92.85354285714249 sekundi
Prosjecno vrijeme drugog testa nakon 10000 izvođenja je 70.45789714285726 sekundi
Prosjecno vrijeme treceg testa nakon 10000 izvođenja je 67.08043619047652 sekundi
Prosjecno vrijeme cetvrtog testa nakon 10000 izvođenja je 70.8654152380956 sekundi

Prosjecno vrijeme prvog testa nakon (zboj vremena po osima X i Y) 10000 izvođenja je 117.53756190476318 sekundi
Prosjecno vrijeme drugog testa nakon (zboj vremena po osima X i Y) 10000 izvođenja je 93.8008952380955 sekundi
Prosjecno vrijeme treceg testa nakon (zboj vremena po osima X i Y) 10000 izvođenja je 94.62250666666779 sekundi
Prosjecno vrijeme cetvrtog testa nakon (zboj vremena po osima X i Y) 10000 izvođenja je 98.56382095238149 sekundi


```

**Slika 43. Rezultati programa za 10 000 uzoraka**

Usporedbom svih rezultata dolazi se do zaključka kako je neovisno o tome radi li se o vožnji simultanim kretanjem ili rektilinearnim kretanjem, vrijeme se povećava s povećanjem veličine narudžbe, osim u slučaju veličina regala  $10 \times 25$  i  $10 \times 75$  kad je kod manjeg regala, a veće narudžbe, potrebno više vremena za jedan ciklus u slučaju primjene TSP-a ili kombinacije TSP-a i band heuristike.

Kada se uspoređuju rezultati simultanog i rektilinearnog kretanja, vidi se da su svi rezultati nešto veći tj. vremena ciklusa su duža kod rektilinearnog kretanja što je i logično jer se prvo koristi brzina u jednom smjeru pa brzina u drugom smjeru dok su kod simultanog kretanja brzine uključene istovremeno.


Na sljedećoj slici je dana usporedba prosječnog vremena trajanja vožnje za 50 posjećenih lokacija.



**Slika 44. Prosječno vrijeme trajanja vožnje za 50 narudžbi**

U izračun su u obzir uzeti rezultati za veličinu narudžbe 50 i na ukupnim rezultatima navedenim u tablici 20. dobiveni su ovi rezultati. Razlika između trajanja simultanog i rektilinearnog kretanja najveća je u slučaju primjene heuristike problema trgovačkog putnika, a najmanja u slučaju klasičnog komisioniranja.

Na sljedećoj slici prikazana je usporedba prosječnog vremena trajanja vožnje za 25 narudžbi.




**Slika 45. Prosječno vrijeme trajanja vožnje za 25 narudžbi**

I u ovom primjeru najveća razlika u vremenu između simultanog i rektilinearnog kretanja je u slučaju primjene heuristike problema trgovačkog putnika, a najmanja kod klasičnog komisioniranja. Kao i kod slučaja sa 50 narudžbi, ti rezultati su očekivani jer su kod klasičnog

komisioniranja po  $x$  osi vremena kretanja u smjeru osi  $x$  u većini slučajeva puno manja od vremena kretanja u smjeru osi  $y$  pa kada se, kod rektilinearnog kretanja, ta vremena zbroje nije velika razlika. S druge strane kod primjene heuristike problema trgovačkog putnika velike su vrijednosti vremena i u smjeru osi  $y$  i u smjeru osi  $x$ , ali se kod simultanog kretanja uzima samo veća vrijednost, a kod rektilinearnog se oba vremena zbrajaju pa je zato i razlika najveća.

Na sljedećoj slici prikazano je prosječno vrijeme za 10 narudžbi.



**Slika 46. Prosječno vrijeme trajanja vožnje za 10 narudžbi**

Kao i u prethodna 2 slučaja najveća je razlika kod primjene heuristike problema trgovačkog putnika, ali je u ovom slučaju najmanja razlika kod primjene band heuristike.

U tablici su zapisana vremena razlika između vožnje simultanim odnosno rektilinearnim kretanjem.


**Tablica 21. Razlike prosječnog trajanja vožnje u korist simultanog kretanja**

	Klasično [s]	Band heuristika[s]	TSP [s]	TSP + band [s]
<b>50</b>	27,5	29,25	47,4	45,5
<b>25</b>	23,9	26,63	37,8	37
<b>10</b>	23,5	22,2	26,6	26,1

Tablica prikazuje koliko je prosječno kraće vrijeme vožnje kod primjene simultanog kretanja za različite veličine narudžbi. Sa smanjenjem brojem narudžbi pada i razlika između prosječnog

trajanja vožnje. Kod primjene heuristike problema trgovačkog putnika i kombinacije sa band heuristikom ta je razlika najuočljivija, a kod klasičnog komisioniranja najmanje uočljiva.

Izraženo u postocima, ukupno za sve slučajeve (veličine narudžbi), primjenom simultanog kretanja kod problema trgovačkog putnika dobije se 27,2 % kraće vrijeme nego kod primjene rektilinearne kretanja. Kod klasičnog komisioniranja ta je razlika najmanja i iznosi 12,5 %. Na sljedećoj slici prikazani su postoci razlike u korist simultanog kretanja.



Slika 47. Postotak razlike vremena kretanja u korist simultanog kretanja

## 8.2. Usporedba s procijenjenim optimalnim rutiranjem

U poglavlju 5.4.4.1. opisan je optimalan redoslijed izuzimanja. Y. Bozer je u svom doktorskom radu predstavio empirijski model za određivanje vremena vožnje u višestrukome ciklusu.

Sve navedene pretpostavke njegovog modela vrijede i za slučajeve koji se promatraju u ovom radu. Budući da njegov model vrijedi samo ako je broj narudžbi između 3 i 16, optimalan redoslijed izračunat će se samo za prva 3 slučaja koja imaju zadanih 10 slučajno odabranih lokacija (narudžbi).

1.  $X=10$ ,  $a=10$  m,  $b=25$  m,
2.  $X=10$ ,  $a=10$  m,  $b=50$  m,
3.  $X=10$ ,  $a=10$  m,  $b=75$  m,

Za navedena 3 slučaja izračunat će se vrijeme vožnje po optimalnoj ruti TSP-a.

Bozerov model je:

$$E(t) \approx T \left[ \frac{2n}{(n+1)} + 0.114703 \cdot n \cdot \sqrt{Q} - 0.074257 - 0.041603 \cdot n + 0.459298 \cdot Q^2 \right]$$

$3 \leq n \leq 16$  broj lokacija s kojih se izuzimaju dijelovi

T faktor mjere (skalarni faktor)

Q faktor oblika regala

$$T = \max \left\{ \frac{L}{v_x}, \frac{H}{v_y} \right\}$$

$$Q = \min \left\{ \frac{L}{v_x \cdot T}, \frac{H}{v_y \cdot T} \right\}$$

Za navedena 3 slučaja izračunati će se procijenjeno vrijeme vožnje po optimalnoj ruti pomoću spomenutog modela.

### 1. X=10, H=10 m, L=25 m,

$$\text{Faktor mjere } T = \max \left\{ \frac{L}{v_x}, \frac{H}{v_y} \right\} = \max \left\{ \frac{25}{2,5}, \frac{10}{0,42} \right\} = 23,81 \text{ s}$$

$$\text{Faktor oblika } Q = \min \left\{ \frac{L}{v_x \cdot T}, \frac{H}{v_y \cdot T} \right\} = \min \left\{ \frac{25}{2,5 \cdot 23,81}, \frac{10}{0,42 \cdot 23,81} \right\} = 0,4199$$

Očekivano vrijeme vožnje komisioniranja:

$$E(t) \approx T \left[ \frac{2n}{(n+1)} + 0.114703 \cdot n \cdot \sqrt{Q} - 0.074257 - 0.041603 \cdot n + 0.459298 \cdot Q^2 \right]$$

$$E(t) \approx 23,81 \left[ \frac{2 \cdot 10}{(10+1)} + 0.114703 \cdot 10 \cdot \sqrt{0,4199} - 0.074257 - 0.041603 \cdot 10 + 0.459298 \cdot 0,4199^2 \right]$$

$$E(t) \approx 51,24 \text{ s}$$

Vrijeme vožnje po Bozerovom modelu TSP-a je 51,24 s. Već izračunato vrijeme za algoritam najbližeg susjeda TSP-a je 50,95 s. Ako se ta dva rezultata usporede, vidi se da algoritam najbližeg susjeda ipak daje nešto bolje rezultate. Bozerov model je procjena na temelju empirije, pa postoji određena vjerojatnost greške (precijenjenog vremena vožnje). S druge strane, heuristički algoritam može u nekim situacijama pogoditi optimalno rješenje (ili vrlo blizu optimalnog), pa se vjerojatno iz tih navedenih razloga ovdje dogodio slučaj da je po heurističkom algoritmu bolje nego po optimalnom.

## 2. **X=10, H=10 m, L=50 m,**

$$\text{Faktor mjere } T = \max \left\{ \frac{L}{v_x}, \frac{H}{v_y} \right\} = \max \left\{ \frac{50}{2,5}, \frac{10}{0,42} \right\} = 23,81 \text{ s}$$

$$\text{Faktor oblika } Q = \min \left\{ \frac{L}{v_x \cdot T}, \frac{H}{v_y \cdot T} \right\} = \min \left\{ \frac{50}{2,5 \cdot 23,81}, \frac{10}{0,42 \cdot 23,81} \right\} = 0,8399$$

Očekivano vrijeme vožnje komisioniranja:

$$E(t) \approx T \left[ \frac{2n}{(n+1)} + 0,114703 \cdot n \cdot \sqrt{Q} - 0,074257 - 0,041603 \cdot n + 0,459298 \cdot Q^2 \right]$$

$$E(t) \approx 23,81 \left[ \frac{2 \cdot 10}{(10+1)} + 0,114703 \cdot 10 \cdot \sqrt{0,8399} - 0,074257 - 0,041603 \cdot 10 + 0,459298 \cdot 0,8399^2 \right]$$

$$E(t) \approx 64,36 \text{ s}$$

Vrijeme vožnje po optimalnom algoritmu TSP-a je 64,36 s, a po algoritmu najbližeg susjeda 67,08 s. Usporedbom se dolazi do zaključka da optimalan algoritam daje bolje rezultate tj. da je na regalu duplo veće duljine od prethodnog vrijeme vožnje kraće ako se računa po optimalnom algoritmu.

Izraženo postotkom, optimalnim algoritmom postižu se za 4,05 % bolji rezultati od korištenja algoritma najbližeg susjeda.

## 3. **X=10, H=10 m, L=75 m,**

$$\text{Faktor mjere } T = \max \left\{ \frac{L}{v_x}, \frac{H}{v_y} \right\} = \max \left\{ \frac{75}{2,5}, \frac{10}{0,42} \right\} = 30 \text{ s}$$

$$\text{Faktor oblika } Q = \min \left\{ \frac{L}{v_x \cdot T}, \frac{H}{v_y \cdot T} \right\} = \min \left\{ \frac{75}{2,5 \cdot 30}, \frac{10}{0,42 \cdot 30} \right\} = 0,7936$$

Očekivano vrijeme vožnje komisioniranja:

$$E(t) \approx T \left[ \frac{2n}{(n+1)} + 0.114703 \cdot n \cdot \sqrt{Q} - 0.074257 - 0.041603 \cdot n + 0.459298 \cdot Q^2 \right]$$

$$E(t) \approx 30 \left[ \frac{2 \cdot 10}{(10+1)} + 0.114703 \cdot 10 \cdot \sqrt{0,7936} - 0.074257 - 0.041603 \cdot 10 + 0.459298 \cdot 0,7936^2 \right]$$

$$E(t) \approx 79,17 \text{ s}$$

Vrijeme vožnje po optimalnom algoritmu je 79,17 s, a po algoritmu najbližeg susjeda 84,41 s. I u ovom slučaju bolji rezultati dobivaju se računanjem po optimalnom algoritmu, što je i očekivano. Dobiveni rezultat po optimalnom algoritmu je za 6,21 % manji u odnosu na algoritam najbližeg susjeda.

Uzimajući u obzir sva 3 slučaja, zaključuje se da povećanjem regala bolje rezultate daje optimalan algoritam dok je na manjem regalu bolji algoritam najbližeg susjeda.

Kod druga dva slučaja dobiveni su očekivani rezultati.

Algoritam najbližeg susjeda je jedan od jednostavnijih algoritama te bi se određivanje rute po optimalnom algoritmu ili primjenom nekog drugog (naprednijeg) heurističkog algoritma mogli postići i bolji rezultati od prikazanih.



## 9. Zaključak

Današnji svjetski trendovi nalažu da roba mora kupcu biti dostupna odmah te se ista često mijenja što dovodi do povećanja konkurentnosti. Zbog toga su logistički sustavi i projektiranje skladišta vrlo bitan i složen proces te se sve nastoji kompjuterizirati kako bi se olakšao sustav praćenja.

Zaključuje se kako automatizirani skladišni sustavi u odnosu na klasične nude mnoge prednosti. Bez obzira na prednosti automatiziranih skladišnih sustava, klasični sustavi imaju široku primjenu u postojećim skladišnim sustavima jer automatizirani nisu jednostavni za implementaciju zbog svog zahtjeva za velikim početnim kapitalom.

Visokoregalna skladišta sa vrlo uskim prolazima smanjuju vrijeme komisioniranja lakših tereta jer se korištenjem man-up viličara sa zakretnim vilicama komisioniranje vrši na samoj lokaciji. Primjenom takvih skladišta povećava se kapacitet jer se zbog vrlo uskih prolaza između regala može spremati više robe. Isto vrijedi i za person-on-board dizalice koji vrše komisioniranje po principu „čovjek robi“ jer dizalica operatera doveze na samu lokaciju gdje se vrši komisioniranje, a također je vrlo dobra iskoristivost površine i prostora zbog visine regala i uskih prolaza za dizalice.

U radu je analizirano usmjeravanje komisionera u visokoregalnim VNA skladištima različitim metodama. Cilj je bio da se utvrdi potencijal smanjenja vremena vožnje komisioniranja primjenom algoritama trgovačkog putnika, temeljem usporedbe sa uobičajenim načinima kod VNA skladišta odnosno person-on-board sustava.

U radu je iz tog razloga predstavljen i problem trgovačkog putnika te algoritam najbližeg susjeda odabran za analizu.

Izračunata su vremena vožnje komisioniranja na 4 različita načina te se zaključuje kako je komisioniranje korištenjem heuristike problema trgovačkog putnika algoritmom najbližeg susjeda većih količina narudžbi, bez obzira na način kretanja viličara, najbolje jer je potrebno najmanje vremena kako bi se napravio jedan ciklus. Isto tako, kod većih količina narudžbi, kao drugi najbolji način komisioniranja pokazala se kombinacija korištenja band heuristike i algoritma najbližeg susjeda.

Kod manjih količina narudžbi, u većini slučajeva primjena heuristike problema trgovačkog putnika daje najbolje rezultate, ali je u nekim slučajevima ipak bolja primjena band heuristike.

Međutim, heuristika najbližeg susjeda je općenito najlošija heuristika (odabrana je zbog jednostavnosti primjene), te je ostalo mjesta za istraživanje ostalih algoritama problema trgovačkog putnika kako bi se utvrdilo koji način komisioniranja zahtjeva najmanje vremena.

Razvojem tehnologije bit će moguća primjena složenijih algoritama te će se time smanjiti vrijeme komisioniranja što u konačnici dovodi do povećanja produktivnosti, smanjenja troškova i povećanja profita što je cilj svakog poduzeća.

Na kraju, kao generalni zaključak, rezultati provedene analize opravdavaju napor za pronalaženje najboljih načina usmjeravanja komisionera. Mogućnosti ušteda u vremenu vožnje komisioniranja, što dovodi i do skraćivanja ukupnog vremena ciklusa komisioniranja, nisu zanemarive. Ostvarena povećanja produktivnosti, odnosno smanjenje troškova, konstantan su cilj industrijskih inženjera.

## 10. Literatura

- [1] Renko S, Sveučilište u Zagrebu, Ekonomski fakultet, Predavanja iz kolegija „*Poslovna logistika*“, 2014. g.
- [2] Đukić G., Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Predavanja iz kolegija „*Tehnička logistika*“, 2013. g.
- [3] Manzini R., „*Warehousing in the Global Supply Chain*“, 2012. g.
- [4] <http://www.primatlogistika.hr/hr/proizvodi-i-sustavi/skladisna-oprema/regali/konzolni-regali#>, 19.2.2015.
- [5] Miljuš M, Sveučilište u Beogradu, Prometni fakultet; Predavanja iz kolegija „*Industrijski transport*“, 2014. g.
- [6] Piasecki D., „The Aisle Width Decision“ članak sa stranice <http://www.inventoryops.com/>, 23.2.2015.
- [7] Piasecki D., „Lift Truck Basics“ članak sa stranice <http://www.inventoryops.com/>, 21.3. 2015.
- [8] <http://www.pmh-co.com/electronic%20wg.html>, 21.3.2015.
- [9] <http://www.pmh-co.com/narrow.html> 21.3.2015., 21.3.2015.
- [10] <http://www.aisle-master.com/index.php?id=2> ,21.3.2015.
- [11] <http://rackandshelf.com/warehouse-products/vna-turret-trucks-with-swing-mast/>, 21.3.2015.
- [12] <http://www.pem-mag.com/facilities-management/automated-storage-and-retrieval-systems-aisle-changing-cranes-streamline-high-bay-operation>, 31.3.2015.
- [13] <http://www.invata.com/warehouse-automation/automated-storage-and-retrieval-systems-asrs/unit-load-asrs/> 31.3.2015.
- [14] <http://www.invata.com/warehouse-automation/automated-storage-and-retrieval-systems-asrs/mini-load-asrs-crane/> 3.4.2015.
- [15] Lahmar Maher, „*Facility Logistics; Approaches and Solutions to Next Generation Challenges*“, 2008. g.
- [16] Đukić G., Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Predavanja iz kolegija „*Posebna poglavlja tehničke logistike*“, 2013.g.
- [17] Tompkins J. A., White J. A., Bozer Y. A., J. M. A. Tanchoco, „*Facilities Planning*“, 2010.
- [18] Đukić G., Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Predavanja iz kolegija „*Operacijska istraživanja I*“, 2013. g.

- [19] Laporte G., Toth P., Vigo D. „*Vehicle routing: historical perspective and recent contributions*“, 2013. g